

Contagem Automática de Bovinos da Raça Nelore em
Imagens Adquiridas por VANTs Utilizando Rede Neural
Convolucional

Fabricio de Lima Weber

SERVIÇO DE PÓS-GRADUAÇÃO DA FACOM-UFMS Data de Depósito:

Assinatura: _____

Fabricio de Lima Weber

Contagem Automática de Bovinos da Raça Nelore em Imagens Adquiridas por VANTs Utilizando Rede Neural Convolutacional

Dissertação apresentada à Faculdade de Computação -
FACOM-UFMS, como parte dos requisitos para obtenção
do título de Mestre em Computação Aplicada.

Área de Concentração: Tecnologias Computacionais para
Agricultura e Pecuária - Engenharia de Software

Orientadora: Profa. Dra. Maria Istela Cagnin Machado
(Facom)

Coorientador: Prof. Dr. Luiz Orcirio Fialho de Oliveira
(Embrapa Gado de Corte)

Coorientador Externo: Prof. Dr. Sérgio Raposo de
Medeiros (Embrapa Pecuária Sudeste)

**UFMS – Campo Grande, MS
2020**

Ficha catalográfica elaborada eletronicamente pela Biblioteca da UFMS, com os dados fornecidos pelo autor

Weber, Fabricio de Lima

Contagem Automática de Bovinos da Raça Nelore em Imagens Adquiridas por VANTs Utilizando Rede Neural Convolucional / Fabricio de Lima Weber; orientadora Maria Istela Cagnin Machado (Facom); coorientador Luiz Orcirio Fialho de Oliveira (Embrapa Gado de Corte); coorientador Sérgio Raposo de Medeiros (Embrapa Pecuária Sudoeste). – Campo Grande – MS, 2020.

Dissertação (Mestrado Profissional - Área: Tecnologias Computacionais para Agricultura e Pecuária) – Faculdade de Computação, Universidade de Federal do Mato Grosso do Sul, 2020.

1. Drone 2. Inteligência Artificial 3. Gado 4. Pecuária de Precisão 5. Zebuínos. I. (Facom), Maria Istela Cagnin Machado, orient. II. (Embrapa Gado de Corte), Luiz Orcirio Fialho de Oliveira, coorient. III. (Embrapa Pecuária Sudeste), Sérgio Raposo de Medeiros, coorient. externo.

Dedico este trabalho aos familiares e amigos, que contribuíram com palavras de motivação e foram compreensivos com os momentos de ausência.

Essa vitória também é de vocês.

AGRADECIMENTOS

Primeiramente, agradeço a Deus por tudo o que ele tem me proporcionado e, em especial, por ter colocado em minha vida as seguintes pessoas:

A professora Maria Istela, que além de orientadora se tornou uma grande amiga, por acreditar em mim, me ensinar e despertar o gosto pela pesquisa.

Vanessa, muito obrigado por ter me apoiado neste desafio, como mentora, amiga e esposa. João Felipe e Pedro Henrique, pela compreensão e apoio.

Ao Sérgio, professora Débora e demais professores das disciplinas da Facom, por disponibilizarem tempo, conhecimento e apoiar o meu trabalho.

Aos amigos que me ajudaram e inspiraram: Sr. Luiz Antônio da Macal, Roni, Marcel, Hudson e Marcelo Terenciani.

Aos meus colegas de trabalho que me apoiaram e auxiliaram quando foi necessário.

*“As invenções são, sobretudo, o
resultado de um trabalho de teimoso. ”
(Santos Dumont)*

RESUMO

A bovinocultura, que é uma das mais importantes cadeias de produção de alimentos do Brasil, carece de vários incrementos tecnológicos para alcançar maior sustentabilidade. Dentre eles destacam-se, no âmbito deste trabalho, aqueles preocupados com a contagem do número de bovinos para inventário, como rastreamento, identificação e outras finalidades. Assim, o objetivo deste trabalho é definir e testar uma abordagem baseada em aprendizado de máquina através de detecção de objetos para a contagem de bovinos da raça Nelore em imagens capturadas via VANTs. Além disso, desenvolver uma ferramenta de software (SYSCONBOV) que permita, dentre outros requisitos, usar o modelo do experimento para realizar a contagem automática de bovinos em imagens cadastradas na ferramenta. Para alcançar tal objetivo foram definidas três etapas: (i) aquisição, treinamento, validação e teste em quatro modelos da arquitetura YOLOv5 avaliados a partir das métricas *Precision*, *Recall*, $mAP@.5$ e $mAP@.5:.95$; (ii) criação e disponibilização de um serviço Web que realiza a contagem dos bovinos; e (iii) desenvolvimento da ferramenta SYSCONBOV. A satisfação e experiência de uso da SYSCONBOV foram avaliadas sob a perspectiva de diferentes tipos de usuários, como proprietários de fazendas e pesquisadores da área da bovinocultura de corte. Os modelos testados apresentaram pouca variação entre eles, sendo que o modelo YOLOv5-x obteve os melhores resultados com 96% para $mAP@.5$, *Precision* e *Recall*, porém sem diferença estatística entre eles. Já quanto ao software, foi possível observar que a ferramenta desenvolvida atende as necessidades levantadas nos requisitos, possui boa experiência de uso, e permite consumir o serviço Web de contagem dos bovinos.

Palavras-chave: Drone, Inteligência Artificial, Gado, Pecuária de Precisão, Zebuínos.

ABSTRACT

Cattle farming, which is one of the most important food production chains in Brazil, can have great benefit with several technological improvements to achieve greater sustainability. Among them, and from the scope of the present work, those concerned with counting the number of cattle for inventory, tracking, identification and other purposes. Thus, the objective of this work is to develop an approach based on machine learning through object detection for Nellore cattle counting in images captured via UAVs. In addition, to develop a software tool (SYSCONBOV) that allows, among other features, to use the weight file of the experiment to automatically count the bovines in images registered in the tool. To achieve this objective, three steps were defined: (i) the acquisition, training, validation and testing in four models of the YOLOv5 architecture evaluated from the metrics Precision, Recall, mAP @ .5 and mAP @ .5: .95; (ii) the creation and availability of a Web service that performs the counting of cattle, and (iii) the development of the SYSCONBOV tool. SYSCONBOV's satisfaction and user experience were assessed from the perspective of different types of users, such as farm owners, and researchers in the beef cattle industry. The tested models showed little variation between them, and the YOLOv5-x model obtained the best results with 96% mAP@.5 for Precision, Recall, however there was no statistical difference among them. As for the software, it was possible to observe that the developed tool meets the requirements, has good user experience and allows to consume the Web service of cattle counting.

Keywords: Artificial intelligence, Bovine, Drone, Counting, Precision Livestock, UAV, Zebu cattle.

LISTA DE ILUSTRAÇÕES

Figura 1 – Exemplos de processamento de imagens, (a) imagem original, (b) imagem em tons de cinza, (c) imagem com <i>threshold</i> e (d) imagem com detecção de bordas	18
Figura 2 – Distâncias para cálculo do GSD	20
Figura 3–Ilustração do processo de classificação através da arquitetura LeNet, um modelo CNN.	24
Figura 4 – Exemplos de detecção de objetos, pessoas e animais feitos por uma CNN.	25
Figura 5 – Diferença na utilização de detecção de objetos usando um ou dois estágios.	26
Figura 6 – Estrutura da Faster-R CNN. Adaptado de Ren et al. (2015)	26
Figura 7 – Resultados de desempenho da YOLOv5 em comparação com a EfficientDet.	28
Figura 8 – Resultados da aplicação do aumento de dados com CutMix e Mosaico	29
Figura 9 – Metodologia utilizada para o desenvolvimento do trabalho.	31
Figura 10 – Imagem do confinamento da Fazenda Escola da UFMS (a), imagem com sobreposição de bovinos (b) e imagem de bovinos na redondeza (c).	32
Figura 11 – Seleção das coordenadas dos bovinos nas imagem do confinamento da Fazenda Escola da UFMS para treinamento da CNN.	33
Figura 12 –Resultados obtidos durante processamento da YOLOv5.	34
Figura 13 – Diagrama de Caso de Uso da Ferramenta SYSCONBOV.	38
Figura 14 – Visão geral da arquitetura da ferramenta SYSCONBOV.	39
Figura 15 – Diagrama entidade-relacionamento do banco de dados da SYSCONBOV.	40
Figura 16 – Tela de Cadastro da Imagem para Processamento do SYSCONBOV.	41
Figura 17 – Tela de Cadastro da Imagem para Processamento do SYSCONBOV.	42
Figura 18 – Área Administrativa do SYSCONBOV.	43
Figura 19 – Questionário de Satisfação do Usuário da SYSCONBOV.	44
Figura 20 – Resultado do Questionário de Satisfação do Usuário da SYSCONBOV.	44

LISTA DE TABELAS

Tabela 1 – Resultado da YOLOv5 no treino e validação.	22
Tabela 2 – Resultado da YOLOv5 no treino e validação.	34
Tabela 3 – Resultado da melhor época da YOLOv5 no teste.	35
Tabela 4 – Resultado da última época da YOLOv5 no teste.	35
Tabela 5 – Melhoria da ferramenta indicadas pelos avaliadores.	44
Tabela 6 – Lista de trabalhos relacionados	45
Tabela 7 – Relação de técnicas, problemas e quantidade de imagem por estudo	46

SUMÁRIO

1-INTRODUÇÃO	13
1.1 Contextualização, Motivação e Justificativa	13
1.2 Objetivo	14
1.3 Organização do Texto	14
2-EMBASAMENTO TEÓRICO	16
2.1 Considerações Iniciais	16
2.2 Perspectiva do Negócio	16
2.3 Perspectiva Computacional	18
2.3.1 <i>Visão Computacional</i>	18
2.3.2 <i>VANT</i>	19
2.3.3 <i>Aquisição de imagens via VANTs</i>	21
2.3.4 <i>Algoritmos para manipulação das imagens</i>	21
2.4 Aprendizado de Máquina	22
2.4.1 <i>Redes Neurais Convolucionais (CNN)</i>	23
2.4.2 <i>Detecção de Objetos</i>	25
2.5 Considerações Finais	29
3-CONTAGEM AUTOMÁTICA DE BOVINOS NELORE EM IMAGENS	30
3.1 Considerações Iniciais	30
3.2 Metodologia	30
3.3 Abordagem para Contagem de Bovinos da Raça Nelore em Imagens utilizando CNN	31
3.4 Construção do serviço de contagem	36
3.5 Desenvolvimento da ferramenta SYSCONBOV	36
3.5.1 <i>Levantar requisitos</i>	37
3.5.2 <i>Projetar Arquitetura, Implementar e Implantar Ferramenta</i>	39
3.5.3 <i>Exemplo de Uso</i>	41
3.5.4 <i>Testar</i>	43
3.6 Trabalhos Relacionados	45
3.7 Considerações Finais	47
4-CONCLUSÃO	48

4.1 Considerações Iniciais	48
4.2 Contribuições	49
4.3 Limitações	49
4.4 Trabalhos Futuros	50
4.5 Produção Científica	51
REFERÊNCIAS	54
APÊNDICE A	62
APÊNDICE B	64

1. INTRODUÇÃO

1.1 Contextualização, Motivação e Justificativa

No Brasil, a pecuária representa 8,5% do PIB do total (ABIEC, 2020), perfazendo um montante relevante para a economia do país. A cadeia produtiva da pecuária, que compõe grande parte da riqueza e dos empregos gerados no país (DA SILVA e FLORIT, 2013), constitui um dos pilares da economia do estado de Mato Grosso do Sul (MACEDO, 2009), com um total de 20.985.665 de cabeças de gado, representando 9,82% do rebanho nacional de bovinos (ABIEC, 2020).

Uma das características mais importantes da pecuária bovina brasileira é que na sua maioria das vezes é desenvolvida em pastagens (LUIZ et al., 2018). Essa situação gera desafios tanto técnicos, como gerenciais.

Com o intuito de amparar essa cadeia produtiva, pesquisadores da Embrapa (Empresa Brasileira de Pesquisa Agropecuária) apontam demandas por tecnologias, dentre elas a de desenvolver um software baseado em visão computacional e em algoritmos de aprendizado de máquinas com a finalidade de permitir a contagem de bovinos a partir de imagens adquiridas por Veículos Aéreos não Tripulados (VANTs), visando apoio a tomada de decisão de cunho gerencial e, assim, promover ganhos incrementais no sistema produtivo.

Sob essa perspectiva, a contagem de bovinos da raça nelore, no piquete ou pasto, por meio de imagens adquiridas por VANTs, pode permitir uma interpretação mais ampla e rápida da quantidade de bovinos em uma determinada área e apoiar várias tarefas do manejo, dando a chance de intervenções em direção a melhorias técnicas. A raça Nelore foi escolhida por ser a mais utilizada nos rebanhos de bovinos de corte no Estado do Mato Grosso do Sul (VIEIRA et al., 2006) e representa 85% do rebanho nacional.

Alguns métodos e tecnologias vêm sendo utilizados em experimentos para contagem de animais selvagens com a utilização de VANTs. No Sul da Flórida nos Estados Unidos, Liu e Abd-Elrahman (2018) criaram um ortomosaico a partir de imagens aéreas adquiridas por VANTs e, posteriormente, realizaram seu processamento por meio de algoritmos de visão computacional. Nasirahmadi *et al.* (2017) realizaram a aquisição de imagens com câmeras fixas e utilizaram técnicas com visão computacional com o intuito de fornecer informações sobre a situação ambiental da baía, adequação de alimentos e água, saúde, bem-estar e eficiência de produção de porcos e bovinos. Jung e Ariyur (2017) utilizaram VANTs na lida de bovinos, na busca de um melhor manejo de condução dos animais. Nesse trabalho, foram adaptadas coleiras contendo GPS (*Global Positioning System*), permitindo que os bovinos fossem localizados com exatidão pelo VANT. Rivas *et al.* (2018) utilizaram imagem de bovinos adquiridas por VANTs para aprendizado da Rede Neural Convolucional (CNN)¹ e, posteriormente, a utilização de um sistema que analisa vídeos em tempo real para localização e contagem dos animais.

¹ Descrita na Seção 2.4.

Adicionalmente, outros estudos para detecção e contagem de animais apresentaram experimentos apoiados por CNNs, como o trabalho de Barbedo e Koenigkan (2018) que citam pesquisas nesse sentido. Kellenberger *et al.* (2018) e Rivas *et al.* (2018) em seus experimentos utilizaram CNN para detecção de animais, separando o banco de imagens em duas classes (bovinos e fundo), sendo que o segundo fez uso de aumento e transformação dos dados para conseguir um banco de imagens mais robusto. Barbedo *et al.* (2020) utilizaram a CNN YOLOv2 para detecção de bovinos a pasto das raças Nelore e Canchim, alcançando uma precisão média de 97%, com manipulações nas imagens como alterações de canais RGB. Rahmemonfar *et al.* (2019) utilizaram a DisCountNet, que é uma rede de dois estágios que usa teorias das redes de detecção e de mapa de calor, para contagem e detecção de bovinos obtendo 99% de acurácia em sua pesquisa. Shao *et al.* (2019) utilizaram a CNN YOLOv2 em voos de 50 m de altura para aquisição das imagens obtendo 95,7% de precisão nos testes.

Diante dos trabalhos existentes e das necessidades apontadas por pesquisadores da Embrapa Gado de Corte, observa-se a importância de possibilitar a contagem automática de bovinos da raça Nelore em imagens capturadas por VANTs para apoiar a gestão de rebanhos e da propriedade rural, com o intuito de representar uma importante inovação para a atividade pecuária propiciando tomada de decisão mais rápida e eficaz.

1.2 Objetivo

O objetivo geral deste trabalho é proporcionar agilidade no processo de contagem de animais e, também, por estar amparado em um método que independe de manejar os animais, colaborar para o bem-estar animal. Para isso é definida uma abordagem para a contagem automática de bovinos da raça Nelore em imagens capturadas via VANTs. Essa abordagem utiliza detecção de objetos para gerar o modelo da CNN. Para possibilitar o uso do modelo definido na prática, é desenvolvida uma ferramenta (SYSCONBOV) com base nesse modelo para realizar a contagem automática de bovinos distribuídos em piquetes através de imagens adquiridas por VANTs e cadastradas na ferramenta pelo pecuarista ou pelo administrador da propriedade.

Adicionalmente, a solução computacional resultante deste trabalho auxilia os pecuaristas no inventário do rebanho, permitindo conhecer o número de animais em um determinado lote ou piquete, evitando extravio ou troca de animais de lotes e proporciona agilidade no processo de contagem de animais.

1.3 Organização do Texto

Este trabalho está organizado em mais três capítulos. No Capítulo 2, são apresentados os principais conceitos e definições que servem de base para o entendimento e para o desenvolvimento desta dissertação. No Capítulo 3, é apresentada a metodologia utilizada para o desenvolvimento do trabalho. Mais especificamente, a primeira etapa da metodologia trata da definição da abordagem

responsável por criar um modelo para detecção do dorso de bovinos em uma imagem. A segunda etapa foi realizada a construção do serviço de contagem de bovinos, com base no modelo definido na etapa anterior. A terceira e última etapa consistiu do desenvolvimento da ferramenta SYSCONBOV, que usa o serviço criado na etapa anterior. No Capítulo 3, são apresentados os trabalhos relacionados, as lacunas observadas e a importância deste trabalho para atenuá-las. Por fim, no Capítulo 4 é apresentada a conclusão do trabalho, com o detalhamento de suas contribuições, limitações e trabalhos futuros, bem como as produções científicas resultantes desta dissertação. No Apêndice A está descrito o Documento de Requisitos definido durante o levantamento inicial da ferramenta e no Apêndice B é apresentado o manual do usuário da ferramenta SYSCONBOV.

2. EMBASAMENTO TEÓRICO

2.1 Considerações Iniciais

Neste capítulo são apresentadas as definições teóricas utilizadas como embasamento para o desenvolvimento deste trabalho de mestrado. Na Seção 2.2 são apresentados os benefícios econômicos da produção da pecuária de corte, considerando a perspectiva do negócio. Em seguida, é abordado o que se tem estudado com relação ao comportamento bovino e bem-estar animal. Na Seção 2.3 é apresentada uma introdução à visão computacional, aquisições de imagem via VANTs e exemplificação de tipos de algoritmos de manipulação de imagem. Na Seção 2.4 é apresentada uma introdução ao Aprendizado de Máquina. Na Seção 2.5 é apresentada uma introdução à CNN. Na Seção 2.6 é apresentada a definição de Detecção de Objetos e arquiteturas de um e dois estágios. Por fim, na Seção 2.7 são apresentados os argumentos sobre o referencial teórico analisado com a finalidade de apresentar as considerações conclusivas do capítulo.

2.2 Perspectiva do Negócio

O Brasil é um dos principais produtores e exportadores de carne bovina do mundo, sendo que grande parte das riquezas e empregos gerados pela pecuária brasileira fazem parte desta cadeia produtiva (SCHLESINGER, 2010). O país tem alcançado recordes de produção e, principalmente, de produtividade na pecuária, resultado do uso de tecnologia e de conhecimento (COSTA *et al.*, 2018). Assim, também, com a perspectiva de colaborar com a sustentabilidade da atividade, os pecuaristas têm direcionado esforços em busca de modelos de produção mais intensivos nas áreas já abertas (COHN *et al.*, 2014).

De acordo com o relatório anual da Associação Brasileira das Indústrias Exportadoras de Carnes (ABIEC), a cadeia da bovinocultura de corte produziu um capital de R\$ 618,50 bilhões em 2019, o que representa um crescimento de 3,5% em relação a 2018. Já o volume das exportações teve um crescimento de 12,2%, que é relevante para a manutenção do saldo comercial brasileiro positivo (ABIEC, 2020).

O Brasil possui 213,68 milhões de cabeças de gado divididos em 162,53 milhões de hectares, o que representa uma lotação de aproximadamente 1,31 cabeças por hectare (ABIEC, 2020). Diante disso, observa-se que o setor tem representatividade na economia do país e o progresso nas metodologias para criação e abate de bovinos tende a impulsionar ainda mais a economia, consequentemente, tornando o sistema produtivo mais forte e robusto.

A criação de bovinos é entendida como um processo empresarial (BARBOSA e SOUZA, 2007), tendo como objetivo a diminuição de custos com a otimização dos recursos e maximização do lucro (BORTOLUZZO; PEDRINOLA; MARTINS, 2011). Assim surge a pecuária de precisão, processo de obter mais lucro, sanidade, qualidade da carne, menor emissão de gases, maior eficiência com os recursos disponíveis e melhor bem-estar dos animais, com um manejo mais

eficiente utilizando recursos tecnológicos para uma tomada de decisão mais rápida e eficaz (DA SILVA, 2013).

Exemplificando, o apontamento dos animais realizado pelos funcionários da propriedade rural, como único artifício de organizar o manejo dos animais e das pastagens, está tornando-se cada vez mais complexo, diante do crescimento dos sistemas de produção e dos problemas com escassez de mão de obra. Sem dúvida, vem se evidenciando a demanda por tecnologias de precisão para o monitoramento automático de especificações individuais dos animais. Tais tecnologias, devem amparar de forma ágil as tomadas de decisões pelos produtores rurais, para que os dados gerados, permitam uma gestão com eficiência e produtividade (EMBRAPA, 2014).

Além disso, o planejamento do manejo e das rotinas de serviços são tarefas essenciais para criação de gado de corte, tornando-se um item essencial para um plano de ações para a pecuária de cria, recria e engorda (SILVA *et al.*, 2010). As ferramentas de computação podem apoiar essas tarefas. Nesse sentido, Luiz *et al.* (2018) propuseram um sistema computacional composto por elementos de hardware e software para apoiar o manejo da suplementação bovina a pasto.

Ademais, a preocupação crescente dos consumidores com relação ao bem-estar e condições de saúde dos animais influencia diretamente o consumo de produtos da indústria (DE GRAAF *et al.*, 2016). Essa demanda gera para o produtor uma necessidade de acompanhamento das condições de saúde e bem-estar dos animais, o que fomenta pesquisas e desenvolvimento de equipamentos e técnicas para permitir análise dessas condições. Essa tarefa tem sido apoiada por técnicas de visão computacional (MURPHY *et al.* 2014; CAJA *et al.*, 2016; NASIRAHMADI *et al.*, 2015). Segundo pesquisas realizadas, inclusive no Brasil, pode-se afirmar que: a melhoria das práticas de manejo de bovinos, a eliminação de suas vocalizações², a retirada do uso de cães e bastões elétricos diminui consideravelmente os níveis de cortisol, uma vez que o cortisol pode ocasionar problemas de imunidade para os animais (LIMA *et al.*, 2016).

O bem-estar animal na pecuária pode ser definido por parâmetros de comportamento psicológico, como análise das emoções, e do estado clínico, com relação a identificação de doenças e rendimento. Ainda sobre o bem-estar, no sentido de eficiência de produção, autores relatam uso de tecnologias inclusive para monitorar preferências alimentares e de água, bem como os momentos de ócio (NASIRAHMADI *et al.*, 2017). Bercovich *et al.* (2013) usaram algoritmos e técnicas de visão computacional para identificar condições corpóreas, baseados em identificações de pontos anatômicos de vacas e porcos usando imagens 2D, enquanto Spoliansky *et al.* (2016) e Kuzuhara *et al.* (2015) determinaram condições corporais por meio de imagens 3D.

Limitações de movimentos, doenças que alteram a temperatura corporal dos animais, provocados pelo ataque por carrapatos e moscas do chifre, mastite e muitas outras enfermidades foram alvo de pesquisas usando análise de imagens (STEPHEN *et al.*, 2017; BERRY *et al.*, 2003; HARRIS-BRIDGE *et al.*, 2018; BARBEDO *et al.*, 2018; CORTIVO *et al.*, 2016). Comportamento de locomoção e rastreamento de movimento foram motivos de pesquisas com equipamentos de coleta de imagens e processamento automatizados (LEE *et al.*, 2012; LAO *et al.*, 2016).

² Processo de emissão de sons dos animais.

Identificação precoce de doenças que podem ser identificadas com alterações de locomoção, quando o animal se aquieta ou fica apático receberam atenção de pesquisadores por meio de técnicas de computação oriundas de visão computacional (PLUK *et al.*, 2012). Adicionalmente, com o intuito de analisar o comportamento ingestivo dos animais, em especial bovinos e suínos, tanto com relação a alimentos quanto a água, Porto *et al.* (2015) analisaram técnicas de coleta e interpretação de imagens.

2.3 Perspectiva Computacional

Com base na literatura citada, a pecuária de precisão pode se beneficiar de várias áreas da computação, dentre as quais a visão computacional, no sentido de extrair dados de imagens e processá-los por meio de algoritmos de inteligência artificial para gerar dados possíveis de interpretação para solucionar problemas (CÁCERES *et al.*, 2011). O uso de VANTs para captura de imagens resguarda a característica de ser menos invasivo e mais inovador no uso de tecnologia aplicada a essa atividade.

2.3.1 Visão Computacional

O sistema visual humano não tem dificuldade em interpretar imagens em relação às suas variações sutis na translucidez e sombreado. Percebemos a estrutura tridimensional do mundo, as cores, profundidade e as emoções nas pessoas à nossa volta com aparente facilidade. Todo esse complexo processo de reconhecimento, em suma, é realizado pela captura da luz pelos nossos olhos e interpretado pelo cérebro por meio de reconhecimento de padrões, contexto, memória e emoções (FORSYTH; PONCE, 2012).

A visão computacional é uma área da Ciência da Computação com a tarefa de processar imagens adquiridas através de uma câmera eletrônica (NIXON e AGUADO, 2002), e emprega um conjunto de técnicas para adquirir, processar e analisar imagens a fim de reproduzir em sistemas a capacidade humana da visão e assim amparar análises do ambiente ou objeto (JAHNE e HAUBECKER, 2000). A aquisição das imagens, na maioria das vezes é efetuada por meio de dispositivos eletrônicos, como câmeras fotográficas e filmadoras digitais (SOUZA, 2010). Após a aquisição, alguns exemplos de processamento são executados conforme apresentados na Figura 1, para obter dados importantes da imagem com o intuito de alcançar um determinado objetivo específico, como, o reconhecimento e a classificação de animais.




Figura 1 – Exemplos de processamento de imagens: (a) imagem original, (b) imagem em tons de cinza, (c) imagem com limiar e (d) imagem com detecção de bordas

Com o objetivo de aumentar a qualidade da imagem, a etapa de pré-processamento torna-se de suma importância para que não haja interferências e imperfeições nas etapas futuras. Nessa etapa, são realizados os processos de redução de distorções e brilho da imagem. Posteriormente, é realizada a segmentação da imagem aplicando técnicas para extração dos objetos de interesse (SZELISKI, 2010). A próxima etapa é capturar as informações que permitam a definição dos objetos de interesse, desta maneira as características extraídas podem ser reconhecidas matematicamente a fim de classificar objetos similares na imagem (QUINTA, 2013). Finalmente, técnicas de aprendizagem automática são utilizadas para criar uma base de conhecimento com relação aos objetos de interesses adquiridos na etapa anterior, a fim de que sejam analisados de maneira automática, permitindo que sua identificação e reconhecimento possam ser feitos através do conjunto de objetos existentes (SZELISKI, 2010).

A visão computacional, inteligência artificial, aprendizado de máquina e mineração de dados são áreas da computação que têm se destacado na pesquisa sobre temas relacionados à agropecuária (CÁCERES *et al.*, 2011; BORTH *et al.*, 2014; GORA *et al.*, 2018). Portanto, esta área da visão computacional depende de muitos parâmetros para configurar técnicas e procedimentos, assim, os resultados obtidos neste trabalho terão que ser avaliados estatisticamente para confirmar sua eficácia.

2.3.2 VANT

Veículos Aéreos Não Tripulados (VANTs) é o nome oficial atribuído aos drones pela Agência Nacional de Aviação Civil (ANAC). Estes são pequenas aeronaves divididas em duas classes: RPA (Aeronave Remotamente Pilotada) ou RPAS (Sistema de Aeronave Remotamente Pilotada). Os RPAs são aeronaves pilotadas remotamente através de uma interface com um computador ou com um dispositivo digital, um simulador e o controle remoto, já os RPAS são aeronaves controladas por sistemas por meio de uma estação de pilotagem remota (BRASIL, 2015).

Os VANTs também podem ser classificados conforme seu uso, como esporte, lazer, competição ou hobby. Neste último caso, essas aeronaves são também chamadas drone ou aeromodelismo. Se o uso for para fins de comércio, pesquisa ou experimentos essas aeronaves são denominadas VANTs (DEBIASI; PERIN; ALVES, 2018). Atualmente, a maioria dos VANTs utilizados em aplicações no campo da agricultura e da engenharia são alternativas competitivas tratando-se de custo e tempo para as tecnologias convencionais utilizadas no levantamento geodésico³ (SIEBERT; TEIZER, 2014).

Os usuários desta tecnologia podem definir como investir para aquisição do seu equipamento especificando algumas características de operação como a capacidade de carga, o alcance de voo, durabilidade e autonomia do equipamento. Ainda com relação às características, a aquisição de imagens está diretamente relacionada ao tipo de câmera ou ao sensor que será usado.

³ Geodésia é a ciência que estuda as dimensões, forma e o campo de gravidade da Terra, permitindo analisar, medir e representar o espaço geográfico do planeta com precisão.

Jorge e Inamasu (2014) descreveram algumas câmeras existentes no mercado e suas possíveis utilizações na agricultura de precisão. Dentre elas, (i) as câmeras RGB são utilizadas na detecção de falhas de plantio, desenvolvimento da cultura, formação da planta, modelo de elevação do terreno; (ii) as câmeras térmicas (*Short Wave Infrared* – SWIR) são utilizadas na detecção de estresse hídrico/irrigação ou ainda para encontrar animais perdidos; (iii) as câmeras multi-espectrais (Infravermelho Próximo– NIR) podem detectar estresse nutricional, determinar índices fisiológicos, e estrutura da copa, utilizando alguns cálculos matemáticos; e (iv) as câmeras hiper-espectrais possuem novos índices e métodos de visualização de assinatura do espectro refletido e geração de índices espectrais combinados, além disso, são utilizadas para a calibração de bandas multi-espectrais.

Para calcular a área da cobertura de uma imagem adquirida por VANTs, primeiramente deve-se encontrar o GSD (*Ground Sample Distance*). GSD é o produto da largura do sensor (S_w) pela altura do voo (H) multiplicado por 100, e posteriormente, dividido pelo comprimento focal (F_r) multiplicado pela largura da imagem em pixels (imW), conforme equação (1). Nas equações (2) e (3) é apresentado o cálculo para obtenção da largura em metros (DW) e o comprimento (DH) da área coberta também em metros. A Figura 2 exemplifica o cálculo conforme implementado pelo software Pix4D⁴. No site da Propeller⁵ é disponibilizado um software que permite consultar o GSD com diferentes tipos de sensores.

$$GSD = \frac{S_w * H * 100}{F_r * imW} \quad (1)$$

$$DW = \frac{imW * GSD}{100} \quad (2)$$

$$DH = \frac{imH * GSD}{100} \quad (3)$$




Figura 2 – Distâncias para cálculo do GSD

A altura de voo para captura de imagens tem sido discutida em vários trabalhos na literatura (TETILA, 2017; FERREIRA, 2017). Jorge e Inamasu (2014) identificaram em suas pesquisas sobre

⁴ <<https://support.pix4d.com/hc/en-us/articles/202559809-Ground-sampling-distance-GSD->>, acesso em 01/03/2019.

⁵ <<https://www.propelleraero.com/gsd-calculator/>>, acesso em 03/03/2019.

a utilização de VANTs na agricultura de precisão, que a altura de voo em torno de 80 metros é suficiente para evitar colisões com obstáculos e garantir o menor ângulo de distorção na aquisição das imagens. Essa altura pode variar de acordo com o objetivo e variações do relevo, tornando-se assim a altura da imagem importante quesito na aquisição de imagens utilizando VANTs.

2.3.3 Aquisição de imagens via VANTs

Inicialmente os trabalhos de aquisições de imagens aéreas eram feitos através de imagens de satélite ou aeronaves tripuladas. A exemplo do problema de contagem de animais selvagens, com o intuito de saber o tamanho da sua população, Xue *et al.* (2017) utilizaram imagens de satélites argumentando que a aquisição das imagens em terra exige um alto investimento. Outra pesquisa aponta a utilização de imagens adquiridas por satélites para a contagem de animais de diversas espécies selvagens, como aves e mamíferos aquáticos (TERLETZKY e RAMSEY, 2016).

VANTs têm sido usados em atividades de sensoriamento remoto, conforme citado por Salamí (2014), na África do Sul e na Austrália. Essas atividades incluem condução dos rebanhos de ovelhas e de bovinos. Hung (2014) descreveu abordagens de classificação para identificar ervas daninhas em pastos de criação de bovinos na Austrália. Ainda, Hung *et al.* (2012) usaram VANTs e visão computacional para fazer segmentação automática e detecção de copas de árvores em área de pastagem. Jiang *et al.* (2016) desenvolveram um algoritmo para detectar objetos a partir de vídeos adquiridos por VANTs e incluíram os bovinos nessa atividade.

Outras espécies de animais como cervos, lebres ou até mesmo pássaros podem ser rastreadas por VANTs equipados com infravermelho, segundo Solanki (2013). Essa aplicação pode evitar atropelamento dos animais por equipamentos agrícolas. Adicionalmente, o autor sugere o uso de VANTs para rastrear pastos e locais de retirada de plantas para silagem em busca de carcaças de animais em decomposição evitando assim contaminação bacteriana que pode levar ao botulismo⁶.

Monitoramento de bovinos com o uso de VANTs é citado no estudo de Fujii *et al.* (2013). Adicionalmente, Graml e Wigley (2008) descreveram uma caracterização de pontos quentes para identificação automática de áreas de incêndio com uso de VANTs e registraram como problemática o número de cabeças de gado perdidas com incêndios. Andrew *et al.* (2016) usaram um subconjunto de descritores de características aplicados às imagens de dorso de bovinos, com o objetivo de identificar animais da raça holandesa, por meio do algoritmo de máquinas de vetores de suporte.

Deste modo, os VANTs são qualificados para sobrevoar uma criação de bovinos com câmeras de alta resolução, a fim de capturar imagens ricas em detalhes, o que torna possível a criação de um sistema de visão computacional para identificar diferentes problemas com os animais.

2.3.4 Algoritmos para manipulação das imagens

A segmentação é o método para separar o objeto de interesse computacional, podendo ser implementada por meio da separação de uma imagem em diferentes regiões ou objetos, com o intuito de simplificar ou mudar a forma de representação de uma imagem facilitando a sua análise.

⁶ Doença/intoxicação causada pela ingestão e absorção intestinal de toxinas produzidas pelo *Clostridium botulinum*.

O processo de classificação de uma imagem depende diretamente da qualidade do processo de segmentação (SAHA e BANDYOPADHYAY, 2007). Assim, pode-se citar quatro algoritmos de segmentação de imagens baseadas em limites entre duas regiões, sendo eles Felzenszwalb, Quickshift, SLIC e Compact watershed. Esses algoritmos buscam uma representação eficiente e compacta de segmentação de imagem, que irá formar uma grade ou grupo de pixels, como consequência, a pré-segmentação da imagem em conjunto de pixels similares conhecidos como superpixel. Executar a segmentação com eficiência, principalmente quando os animais estão agrupados, é de extrema importância para análise e reconhecimento do objeto de interesse (BARBEDO; KOENIGKAN, 2018). Estes algoritmos podem apoiar o processo de segmentação do dorso dos bovinos, o que é basicamente separação entre bovino e fundo de uma imagem.

2.4 Aprendizado de Máquina

O aprendizado de máquina, do inglês *machine learning*, é uma subárea da inteligência artificial, que utiliza-se de técnicas computacionais empregadas na estatística e neurociência para o reconhecimento de padrões (NASRABADI, 2007). Mitchell (1997, p.2) definiu que “um programa de computador é dito aprender a partir de uma experiência E com respeito a uma classe de tarefas T e medida de desempenho P , se seu desempenho nas tarefas em T , segundo a medida P , melhora com a experiência E ”. Essas técnicas computacionais podem ser aplicadas em conjunto com técnicas de visão computacional, buscando resolver problemas comuns aos seres humanos, porém complexos para os computadores. Esses problemas, na maioria das vezes, corresponde a problemas de classificação ou de regressão.

Deste modo, o aprendizado de máquina tem características que permitem classificar os sistemas de aprendizado de máquina de acordo com o seu: modo de aprendizado, paradigma de aprendizado, linguagem de descrição, forma de aprendizado e tarefa de aprendizado, conforme apresentado na Tabela 1 e descrito a seguir.

Tabela 1 – Aprendizado de Máquina e suas características (Patri, 2006)

Classificação dos Sistemas de Aprendizado de Máquina				
Modo de Aprendizado	Paradigma de Aprendizado	Linguagem de Descrição	Forma de Aprendizado	Tarefa de Aprendizado
Supervisionado	Simbólico	Exemplos	Incremental	Classificação
Não Supervisionado	Estatístico	Hipóteses	Não Incremental	Regressão
Semi Supervisionado	Conexionista	Conhecimento de domínio		
	Genético			

No modo de aprendizado supervisionado é aplicado ao sistema de aprendizado uma base de dados com exemplos onde suas saídas são conhecidas pelo valor da classe na qual o exemplo

pertence. No modo de aprendizado não supervisionado, presume-se que não se conhece a classe na qual os exemplos pertencem. Já o modo de aprendizado semi-supervisionado faz uma junção dos dois modos anteriores, onde uma parte do conjunto é rotulada e a outra não. O paradigma de aprendizado pode ser representado por estruturas gráficas ou lógicas para apresentar o que foi aprendido, por exemplo, utilizando expressões lógicas, regras de produção, árvores de decisões, entre outras.

Para atender diferentes linguagens de descrição com complexidades distintas são utilizados os exemplos, que são os casos a serem observados, a hipótese e o conhecimento de domínio que podem ser exemplificados com lógica de atributos, lógica relacional, lógica proposicional ou por funções matemáticas.

A forma de aprendizado pode ser classificada em incremental e não incremental. No modo incremental a entrada dos dados não é feita simultaneamente, podendo informar novos modelos para o algoritmo de aprendizagem. No entanto, no modo não incremental a entrada dos dados é feita simultaneamente no começo do aprendizado. A tarefa de aprendizado pode ser por classificação ou por regressão. Na classificação, o objetivo é identificar a qual classe pertence um determinado objeto, como a predição de bovino ou fundo, já na regressão o objetivo é prever um valor numérico, como identificar uma categoria do problema em escala contínua, podendo ser utilizada nas regressões linear e logística, por exemplo na predição do peso de um bovino.

Para apoiar o processo de aprendizagem de máquina, o software WEKA foi desenvolvido em linguagem de programação Java pela Universidade de Waikato⁷. Este software permite a aplicação e comparação de várias técnicas de aprendizagem de máquina já desenvolvidas e consolidadas. Isso se dá através da entrada de um conjunto de dados, após aplicação de algoritmos, obtém-se a predição de resultados ou padrões. O software permite ainda que se faça validações dos modelos gerados através de métricas como: coeficientes de correlação, precisão, revocação, medida-f, matriz de confusão, entre outros (HALL *et al.*, 2009). Como exemplo de algoritmos que aplicam aprendizado de máquina para o processo de classificação podem-se citar KNN, SVM e J48.

2.4.1 Redes Neurais Convolucionais (CNN)

Redes Neurais Convulsionais são um tipo de redes neurais artificiais criadas para processar dados em grande escala com o menor uso de processamento em comparação a redes neurais artificiais, uma vez que ocorre a redução de processamento através do uso de cálculos convolucionais diferentemente da rede neural artificial que utiliza multiplicação de matrizes no cálculo de pesos de camadas ocultas (GOODFELLOW *et al.*, 2016). Essa intervenção convolucional afeta três aspectos essenciais de um sistema de aprendizagem automática: compartilhamento de parâmetros, interações esparsas e representações invariantes (LECUN *et al.*, 2015).

A LeNet foi uma das primeiras CNNs propostas, conforme LeCun *et al.* (2015), para o reconhecimento óptico de caracteres. A rede neural artificial tradicional visa calcular peso apenas

⁷ <<https://www.waikato.ac.nz/>>

uma vez a cada camada, essas camadas são os níveis do processo de uma rede. Isso significa que todos os pesos de uma camada serão recalculados a cada iteração, implicando em maior quantidade de processamento. Em uma CNN, os parâmetros são fixos e o número de conexões neurais reduzidas, portanto, não são mais completamente conectadas, assim o núcleo de uma transação convolucional sempre terá seu tamanho reduzido comparado com a entrada. Além disso, o compartilhamento de parâmetros também traz a vantagem da representação constante, permanecendo certas características de entrada (GOODFELLOW *et al.*, 2016).

Os elementos de uma camada de convolução são organizados em esquemas de características em que são conectados a fragmentos locais nos mapas de atributos das camadas anteriores através de um conjunto de pesos. Esses pesos, também descritos como banco de filtros, integram a soma local ponderada de cada camada que, por sua vez, passa por uma função de correção a fim de eliminar valores negativos. O banco de filtros pode compartilhar os elementos do mapa de características, mas diferentes mapas de filtros usam diferentes bancos de filtros. A principal função da camada de convolução compreende em detectar conjunções locais de atributos de camadas anteriores (LECUN *et al.*, 2015).

O agrupamento semântico de características ocorre na camada de *pooling*, que é usada para reduzir as dimensões espaciais do pixel. Como as posições relativas das características são constantes, uma identificação confiável de padrões é possível refinando a posição de cada característica (LECUN *et al.*, 2015). Consequentemente, obtém-se uma maior eficiência computacional visto que diminui o tamanho da entrada anterior conservando as características. Ao final da rede, uma simples camada completamente conectada calcula as classificações das classes definindo sua saída (GOODFELLOW *et al.*, 2016), conforme Figura 3, que exemplifica a arquitetura da uma rede GoogLeNet (2014) simplificada da Google também conhecida como Inception V1. Além dessa arquitetura pode-se citar a VGGNet (2014), AlexNet (2012), ResNet (2015), entre outras.




Figura 3 –Ilustração do processo de classificação através da arquitetura LeNet, um modelo CNN.
Adaptado de Ren *et al.* (2015)

Atualmente é possível encontrar diversas bibliotecas de Inteligência Artificial que implementam as principais operações utilizadas nas CNNs. As mais utilizadas são: YOLO (REDMON *et al.*, 2016), Caffe (JIA *et al.*, 2014), MatConvNet (VEDALDI e LENC, 2015), Theano

(AL-RFOU *et al.*, 2016), Torch (COLLOBERT *et al.*, 2011) e TensorFlow (ABADI *et al.* 2015). Essas bibliotecas disponibilizam execução em múltiplas CPUs ou GPUs, e são usadas por diversas empresas para reconhecimento de objetos, conforme Figura 4.




Figura 4 – Exemplos de detecção de objetos, pessoas e animais feitos por uma CNN.
Adaptado de Ren *et al.* (2015)

2.4.2 Detecção de Objetos

A utilização das CNNs para reconhecimento de objetos ocorre na sua grande maioria em sistemas de recomendação, que auxiliam na indicação de um objeto em determinada tarefa e que utilizam modelos de CNNs lentos e precisos (BOCHKOVSKIY *et al.*, 2020). Como recursos são extremamente importantes para a execução de processamento de imagens. Na última década, na tarefa de reconhecimento visual, inicialmente utilizavam as técnicas de SIFT e HOG (LOWE, 2004; DALAL and TRIGGS, 2005), seguidos pela técnica de reconhecimento visual canônico, através da detecção de objetos VOC PASCAL, que era um processo lento (EVERINGHAM *et al.*, 2010). Novas técnicas para detecção de objetos foram aparecendo durante estes anos, modelos que geram regiões propostas independentes de categorias, que definem um conjunto de detecções candidatas chamadas de *Bounding Boxes*, em seguida uma CNN utiliza essas regiões propostas para criação de um mapa de característica, assim tornando esse processo mais rápido e preciso. Desse modo são apresentados dois tipos de detectores, com um e dois estágios, descritos a seguir. Ambos avaliam o desempenho da CNN levando em conta o acerto em relação a localização e classificação do objeto, conforme Figura 5.

- Detectores de Um-Estágio: *Single Shot Detector* (SSD) (LIU *et al.*, 2016, QIN *et al.*, 2019), *You Only Look Once* (YOLO) (REDMON *et al.*, 2016) e *RetinaNet* (LIN *et al.*, 2017), como o próprio nome descreve é composta por somente um estágio, sendo as tarefas localizar o objeto e classificar feitas em um única direção.

- Detectores de Dois-Estágios: *Region Proposal Network* (R-FCN) (REN *et al.*, 2015), *Fast Region-based Convolutional Network* (Fast R-CNN) (GIRSHICK *et al.* 2015; AMIN e GALASSO, 2017), *Faster Region-based Convolutional Network* (Faster R-CNN) (REN *et al.*, 2015) e *Mask Region-based Convolutional Network* (Mask R-CNN) (HE *et al.*, 2017). Diferentemente do modelo

anterior, este processo de detecção foi implementado com dois estágios, no primeiro estágio é feita a localização dos objetos na imagem e no segundo estágio é realizada a classificação dos mesmos.




Figura 5 – Diferença na utilização de detecção de objetos usando um ou dois estágios.

Fonte: Bochkovskiy *et al.* (2020)

Exemplificando, a Fast R-CNN é formada por uma rede de região proposta (RPN) para gerar região com possíveis objetos de interesse e uma segunda rede que utiliza estas regiões propostas para detectar os objetos, como apresentado na Figura 6. A principal diferença da Fast R-CNN em comparação com as outras redes que utilizam dois estágios é a utilização de uma pesquisa seletiva para gerar propostas de região. O custo de tempo para gerar propostas de região é muito menor na RPN do que na pesquisa seletiva, quando a RPN compartilha mais computação com a rede de detecção de objetos. Resumidamente, o RPN classifica as caixas de região (chamadas âncoras) e propõe as que provavelmente contêm objetos.




Figura 6– Estrutura da Faster-R CNN. Adaptado de Ren *et al.* (2015)

Na Faster R-CNN, após a entrada da imagem na rede, inicialmente passa pelo *backbone* para obter o mapa de recursos. A principal vantagem em utilizar esse método é que há o compartilhamento entre o *backbone* PRN e o *backbone* do detector da Faster R-CNN. Após este passo as propostas de caixa delimitadora do RPN são usadas para agrupar recursos do mapa de recursos de *backbone*. Isso é feito pela camada de pool de ROI. A camada de pool de ROI, em essência, funciona da seguinte forma: a) Selecionar uma região correspondente a uma proposta do mapa de recursos do backbone; b) Dividir esta região em um número fixo de sub-janelas; c) Realizar o pool máximo nessas sub-janelas para obter uma saída de tamanho fixo. Posteriormente, a saída da camada de pool de ROI tem N números de propostas que passam por duas camadas totalmente conectadas. Estes resultados são enviados para os ramos de classificação e regressão da rede.

Os ramos de classificação e de detecção da rede Faster R-CNN são diferentes dos da RPN. Na Faster R-CNN a camada de classificação apresenta X unidades para cada uma das classes da função de detecção. Os resultados são transferidos para uma camada softmax que obtém uma pontuação de classificação (probabilidade de uma objeto pertencer a cada classe). Posteriormente, são encaminhados os coeficientes da camada de regressão para definir o melhor posicionamento das caixas delimitadoras, assim selecionando e demarcando todos os objetos de interesses de uma imagem.

Outro exemplo é a YOLO, a qual é uma CNN que propõe a detecção de objetos em tempo real e que pode identificar com maior precisão vários objetos em um único quadro. A YOLO é 1000x é mais veloz que a R-CNN e 100 vezes mais veloz que a Faster R-CNN (REDMON and FARHADI, 2018), que facilita a utilização de GPUs de menor desempenho em trabalhos que empregam estes tipos de CNN. YOLOv5 alcança o estado da arte para detecção de objetos, foi lançada em 9 de Julho de 2020 e é uma derivação da YOLOv3 e YOLOv4 (JOCHER *et al.*, 2020). É uma rede nativa em PyTorch, enquanto todas as versões anteriores da família YOLO utilizam o Darknet. A nova versão deste modelo ficou bem mais fácil para instalar, demandando uma única linha de comando (!pip install -U -r yolov5/requirements.txt), sendo que o arquivo txt contém todas as dependências necessárias para sua utilização. Este modelo apresenta quatro modelos distintos com o tamanho de seus pesos, a versão extra-grande ‘v5x’ com tamanho de 367 MB, a versão grande ‘v5l’ com tamanho de 192 MB, a versão média ‘v5m’ com tamanho de 84 MB e a versão pequena ‘v5s’ com 27 MB de tamanho. A Figura 7 mostra a comparação das versões da YOLOv5 com a EfficientDet.




Figura 7– Resultados de desempenho da YOLOv5 em comparação com a EfficientDet.

Fonte: <https://github.com/ultralytics/yolov5>

A YOLOv4 utiliza em sua arquitetura: (i) *Bag of Freebies* (BoF) para backbone: aumento de dados CutMix e Mosaico, regularização DropBlock, suavização de etiquetas de classe; (ii) *Bag of Specials* (BoS) para backbone: ativação Mish, conexões parciais de estágio cruzado (CSP), conexões residuais ponderadas por várias entradas (MiWRC); (iii) *Bag of Freebies* (BoF) para detector: perda de CIoU, CmBN, regularização do DropBlock, aumento de dados em mosaico, treinamento autoconservador, elimina a sensibilidade à grade, uso de múltiplas âncoras para uma única verdade do solo, programador de recozimento de cosseno, hiperparâmetros ótimos, aleatório formas de treinamento; e (iv) *Bag of Specials* (BoS) para detector: ativação Mish, bloco SPP, bloco SAM, bloco de agregação de caminho PAN, DIOU-NMS. Pode-se observar na Figura 8 a aplicação de alguns desses métodos propostos por esta arquitetura, exibindo a montagem de mosaicos com os animais identificados.

O funcionamento básico do detector de objetos proposto pela YOLO é trabalhar online para ter uma melhor precisão sem aumentar o custo de inferência. Este método é chamado de “*Bag of Freebies*” que utiliza o aumento dos dados objetivando uma maior variabilidade das imagens utilizadas pela CNN. Para alcançar esse resultado são aplicados dois métodos de aumento de dados: distorções fotométricas e distorções geométricas, que facilitam a tarefa de detecção de objetos. Outro diferencial destas CNN’s são os “*Bag of Specials*” que são aplicados nos módulos de extensão e métodos de pós-processamentos que aumentam o custo de inferência em um pequeno percentual, auxiliando no ganho de precisão na detecção dos objetos da YOLO. Em consequência destas funcionalidades e de uma maior precisão na detecção dos objetos de interesse, justifica-se a escolha da arquitetura YOLO para se aplicar neste trabalho.



Figura 8– Resultados da aplicação do aumento de dados com CutMix e Mosaico nas imagens utilizadas no treino da YOLOv5.

2.5 Considerações Finais

Neste capítulo foi apresentado o embasamento teórico necessário para entendimento e desenvolvimento de uma abordagem apoiada computacionalmente e baseada em visão computacional, que utiliza imagens de bovinos nelore capturadas de VANTs para possibilitar a contagem desses animais, de forma prática e rápida, favorecendo a eficiência administrativa, pois a contagem manual de animais demanda muito tempo e mão-de-obra nas propriedades.

No próximo capítulo são apresentados a abordagem definida para contagem de bovinos da raça nelore em imagens capturadas via VANTs, a construção do serviço de contagem, o desenvolvimento da ferramenta SYSCONBOV que utiliza esse serviço e os trabalhos relacionados, que contribuíram para o levantamento das lacunas existentes na literatura e para a definição do alinhamento do escopo deste trabalho.

3. CONTAGEM AUTOMÁTICA DE BOVINOS NELORE EM IMAGENS

3.1 Considerações Iniciais

Neste capítulo, é apresentada a abordagem proposta para a contagem de bovinos em imagens capturadas via VANTs baseada em processamento de imagem (em especial, utilizando redes Faster R-CNN e YOLOv5), bem como a ferramenta Web de apoio construída denominada SYSCONBOV. Mais especificamente, na Seção 3.2, é descrita uma visão geral da metodologia utilizada para o desenvolvimento do trabalho, composta por três etapas: (i) abordagem estabelecida para treinamento e validação da rede, obtendo um modelo de rede para utilizar na contagem dos objetos de interesse, (ii) construção do serviço de contagem baseado no modelo definido na etapa anterior, e (iii) desenvolvimento da ferramenta Web de apoio. Na Seção 3.3, são descritas as atividades realizadas para a definição da abordagem proposta. Na Seção 3.4, são apresentadas as atividades realizadas para a construção do serviço de contagem e na Seção 3.5 são descritas as atividades executadas para a desenvolvimento da ferramenta Web de apoio, que utiliza o serviço de contagem. Na Seção 3.6, são apresentados os trabalhos relacionados, destacando as lacunas encontradas na literatura que são preenchidas por este trabalho. Por fim, na Seção 3.7, apresentam-se as considerações finais do capítulo.

3.2 Metodologia

A metodologia utilizada é composta por três etapas, conforme apresentadas na Figura 9. A primeira etapa é referente ao treinamento, validação e teste da CNN proposta que é direcionada à contagem de bovinos da raça nelore com base em imagens adquiridas por VANTs por meio da detecção de vários objetos em uma única imagem, com o intuito de diminuir os custos de monitoramento do rebanho, bem como contribuir para a melhoria do bem estar animal.

A segunda etapa trata da criação e disponibilização de um serviço que realiza a contagem dos bovinos. A terceira e última etapa da abordagem consiste no desenvolvimento da ferramenta SYSCONBOV que utiliza o serviço de contagem disponibilizado pela etapa 2. Os detalhes sobre a execução de cada etapa são apresentados nas próximas seções.

Inicialmente, na primeira etapa, foram capturadas imagens de bovinos por VANTs. Essas imagens são utilizadas para treinamento e teste de uma CNN com objetivo de aprender a reconhecer o dorso dos animais, em seguida, é gerado um arquivo de peso contendo o modelo da rede obtido a partir da validação das imagens restantes, permitindo, assim, contar os animais em uma imagem.

Em paralelo a etapa de Treinamento da Rede, iniciou-se o desenvolvimento do serviço de Contagem de bovinos. Para a implementação desse serviço foram aproveitados códigos de testes da YOLOv5. O resultado da contagem dos bovinos em cada imagem e a respectiva imagem com a marcação dos bovinos contados por meio de um retângulo em volta dos mesmos são armazenados.

Em seguida, iniciou-se o desenvolvimento da SYSCONBOV que realiza a contagem dos bovinos com apoio do serviço desenvolvido a partir do envio de imagens, capturadas por VANTs, pelos produtores. Todas as etapas estão detalhadas nas próximas seções.




Figura 9 – Metodologia utilizada para o desenvolvimento do trabalho.

3.3 Abordagem para Contagem de Bovinos da Raça Nelore em Imagens utilizando CNN

Para iniciar a definição da abordagem proposta neste trabalho, foi necessária a criação de um banco de imagens. Para a aquisição de imagem de bovinos foi utilizado o

VANT modelo Phantom 3 Advanced com câmera Sony EXMOR 1/2.3" com 12.4 Megapixel, e uma lente f/28 que possui um campo de visão de 94° que evita distorções na imagem. Este VANT possui uma largura do sensor da câmera de 6,17 mm, uma distância focal da câmera de 3,57 mm, gerando uma imagem de resolução de 4000 x 3000 pixels. Voando à 100 metros de altura cobre uma área de 22.490 m² (173 x 130), que equivale ao GSD de 4,32 cm/px.

O local escolhido para a captura das imagens foi a Fazenda Escola da UFMS localizada no município de Terenos - MS. As imagens foram obtidas durante o manejo dos animais, ou no horário de alimentação (Figura 10(a)) às 9:00hs e às 16:00hs aproximadamente. Foram coletadas 1139 imagens através de voos de 20, 40, 80 e 100 metros de altura com GSD correspondentes a 0,86 cm/px, 1,73 cm/px, 3,46 cm/px e 4,32 cm/px, sendo utilizadas 878 imagens que continham animais. Como os animais estavam alojados em piquetes de confinamento individuais, havia pouca sobreposição da imagem do bovino (Figura 10(b)). Na maioria dos casos os bovinos encontravam-se sobre o solo de terra, porém, alguns animais da redondeza foram considerados para este banco de imagens (Figura 10(c)).



Figura 10 – Imagem do confinamento da Fazenda Escola da UFMS (a), imagem com sobreposição de bovinos (b) e imagem de bovinos na redondeza (c).

Inicialmente foram feitos treinos que utilizavam a entrada de dados para CNN com objetos segmentados por superpixel, onde todas as imagens eram segmentadas e esses segmentos eram separados em duas classes “bovinos” e “fundo”. Como o processo de

segmentação não é automatizado e é muito trabalhoso e demorado, inviabiliza a sua utilização em algumas pesquisas. Para alcançar resultado mais vantajoso, neste trabalho foram escolhidos modelos que utilizam coordenadas dos objetos de interesses na imagem, dispensando a segmentação da imagem.

Posteriormente, foi realizada a identificação das coordenadas dos animais na imagens coletadas, manualmente, formados pelos seguintes atributos: nome da imagem, X (coordenada centro de X da caixa delimitadora), Y (coordenada centro de Y da caixa delimitadora), *width* (largura da caixa delimitadora) e *height* (comprimento da caixa delimitadora) e o último atributo a classe pertencente. Para isso, foi desenvolvido um sistema computacional para selecionar os bovinos com uma caixa delimitadora, sendo necessário escolher a imagem (Figura 11(a)), selecionar a posição do animal (Figura 11(b)) e gerar as coordenadas das caixas existentes na imagem (Figura 11(c)). Para uma melhor visualização dentro do sistema, as imagens foram redimensionadas de 4000 x 3000 pixels para 800 x 600 pixels. Essas coordenadas são utilizadas para o treinamento da CNN.




Figura 11 – Seleção das coordenadas dos bovinos nas imagem do confinamento da Fazenda Escola da UFMS para treinamento da CNN.

Posteriormente, o banco de imagens foi dividido nos percentuais de 90% das imagens para treino e validação e 10% restantes para teste. Foi definido inicialmente que a arquitetura utilizada para reconhecimento do objeto de interesse em uma determinada imagem seria a FRCNN. A FRCNN é a junção de duas outras redes, a rede de proposta de região (RPN) utilizada para gerar propostas de objetos de interesses em uma região e uma rede usando essas propostas para detectar objetos, ou seja uma rede de classificação, conforme descrito na Seção 2.6. Mas o processamento utilizando a FRCNN demorava em torno de 32 horas para execução. Caso os resultados não fossem satisfatórios, retornava-se na etapa anterior alterando os parâmetros de execução como *data augmentation* com três rotações das imagens de 90° cada (formando novas imagem com 90°, 180° e 270°) e o giro das imagens na vertical e horizontal. Como os resultados não estavam satisfatórios, com acurácia de 96% e 70% para treino e teste respectivamente, optou-se então em testar a

arquitetura YOLOv5, que tem a proposta de ser mais veloz e precisa na detecção de objetos, com a mesma divisão do banco de imagens definida anteriormente para treino e teste.

Foram testados os quatro modelos existentes para YOLOv5, que apresentaram resultados satisfatórios com as métricas para treino e validação da CNN para o melhor modelo, conforme Tabela 2 e Figura 12. Por apresentar melhor desempenho em relação a velocidade e porcentagem de acerto foi escolhido este tipo de CNN para implementação do serviço de contagem. Foram utilizadas as seguintes métricas para avaliar os pesos: (i) perda da Interseção sobre União Generalizada (GIoU loss) nas estruturas de detecção de objetos de última geração, (ii) *Precision* em que todos os bovinos classificados como corretos são efetivamente corretos, (iii) *Recall* ou revocação, referente aos bovinos que foram marcados corretamente, (iv) $mAP@.5$ que é a média de precisão em relação ao limite de Interseção sobre União (IoU) de 50%, e (v) $mAP@.5:.95$ que é a média de precisão em relação ao limite de IoU de 5%.

Tabela 2 – Resultado da YOLOv5 no treino e validação.

Modelo	GIoU loss	Precision	Recall	$mAP@.5$	$mAP@.5:.95$	Tempo de Processamento
YOLOv5-x	0.02248	0.8719	0.9738	0.9623	0.4835	6h21m42s
YOLOv5-l	0.02334	0.8735	0.9767	0.9679	0.4930	3h02m11s
YOLOv5-m	0.02571	0.8488	0.9689	0.9582	0.4951	2h40m20s
YOLOv5-s	0.02937	0.8162	0.9709	0.9653	0.4878	2h29m52s

Fonte: Elaborada pelo autor.




Figura 12 – Resultados obtidos durante processamento da YOLOv5. As cores verde, rosa, vermelho e azul correspondem respectivamente aos modelos YOLOv5-x, YOLOv5-l, YOLOv5-m e YOLOv5-s.

Os seguintes parâmetros padrão foram utilizados para o treinamento: img width, img height = 640 (tamanho da imagem de entrada em pixels); tamanho do batch = 8; número de épocas = 200; otimizador Adam com taxa de aprendizado = 0,001 e momento = 0,937. O tempo total de processamento para a execução do treino e validação foi de aproximadamente três horas. Posteriormente, foi executado um conjunto de teste para verificar a eficácia dos arquivos de pesos gerados na etapa anterior. As Tabelas 3 e 4 apresentam as métricas resultantes da melhor época e da última época do teste, para todos os modelos da YOLOv5, com confiança de 0,05.

Ao analisar a melhor época observa-se que, apesar dos resultados apresentarem pouca variação entre eles, para todas as métricas definidas para este experimento, o modelo YOLOv5-x obteve os melhores resultados. Acredita-se que devido a maior complexibilidade deste modelo generalizou um pouco melhor os dados. No entanto, a partir das métricas da última época, a YOLOv5-x apresentou melhor resultado na recall e mAP@.5 e a YOLOv5-l melhor precision e mAP@.5:.9. Aplicando a ANOVA⁸ (BEYOND, 1986) para todas as métricas, da melhor época e da última época, os modelos não apresentaram diferença estatística.

Tabela 3 – Resultado da melhor época da YOLOv5 no teste.

Modelo	Precision	Recall	mAP@.5	mAP@.5:.95
YOLOv5-x	0.965	0.96	0.954	0.5
YOLOv5-l	0.964	0.948	0.935	0.494
YOLOv5-m	0.956	0.941	0.936	0.478
YOLOv5-s	0.951	0.945	0.935	0.492

Fonte: Elaborada pelo autor.

Tabela 4 – Resultado da última época da YOLOv5 no teste.

Modelo	Precision	Recall	mAP@.5	mAP@.5:.95
YOLOv5-x	0.959	0.964	0.953	0.484
YOLOv5-l	0.964	0.958	0.946	0.488
YOLOv5-m	0.956	0.951	0.943	0.486
YOLOv5-s	0.956	0.946	0.929	0.476

Fonte: Elaborada pelo autor.

⁸ ANOVA - Análise da variância

3.4 Construção do serviço de contagem

O serviço de contagem foi desenvolvido na linguagem Python, aproveitando a estrutura de programação já existente fornecidos pela Ultralytics⁹ (JOCHER *et al.*, 2020), e os dados são armazenados no SGBD (Sistema de Gerenciamento de Banco de Dados) MySQL (ORACLE CORPORATION, 2019). Foi necessária uma adaptação no código existente (função `detect`) para que o mesmo executasse a contagem dos objetos identificados na imagem. Além disso, foi adicionada à programação existente da Ultralytics a conexão do Python com o SGBD e a gravação da imagem em pasta específica do servidor web.

Após a identificação dos bovinos na imagem é realizado o armazenamento do número de bovinos encontrados na imagem, e o status da imagem é alterado de “PROCESSAR” para “PROCESSADO”. O serviço foi validado durante o seu desenvolvimento e, posteriormente, durante a sua utilização pela ferramenta SYSCONBOV, quando o usuário valida a quantidade real de bovinos existente na imagem.

Para a implantação e o funcionamento do serviço de contagem, é necessário instalar o Python e suas dependências na máquina destinada a ser o servidor. Este serviço será invocado automaticamente pela ferramenta SYSCONBOV no momento do cadastro da imagem pelo produtor.

3.5 Desenvolvimento da ferramenta SYSCONBOV

A ferramenta SYSCONBOV tem como objetivo principal efetuar a contagem de bovinos em imagens adquiridas por VANTS, enviadas pelos produtores, com base em CNN. Essa ferramenta permite que os produtores ou administradores de propriedades realizem o envio de imagens (obtidas em suas propriedades via VANTs) para o servidor utilizando uma interface web. Em seguida, o servidor processa as imagens utilizando o serviço de contagem baseado em visão computacional (descrito na Seção 3.4) e retorna para os usuários a imagem processada com os bovinos identificados (por meio de retângulos) e a quantidade de animais obtida.

Como o processamento das imagens para realizar a contagem exige servidores com alta capacidade de processamento, o resultado não é apresentado imediatamente, pois as imagens são enviadas para um servidor da Embrapa que é responsável por identificar os animais contidos na imagem baseando-se na CNN.

Portanto, com a ferramenta é possível que o proprietário monitore o seu gado remotamente, minimizando assim os custos de deslocamento e, também, o tempo dispendido durante as checagens rotineiras de sua propriedade. Além disso, contribui para a melhoria do bem estar animal, pois não há necessidade de aparte dos animais. A ferramenta

também conta com uma área administrativa, onde usuários com permissão de administrador poderão obter informações relacionadas ao rebanho dos proprietários que utilizam a ferramenta. A seguir, são detalhadas as atividades realizadas para a construção da SYSCONBOV.

3.5.1 Levantar requisitos

O levantamento dos requisitos foi realizado através de reuniões, com dois especialistas em nutrição animal da Embrapa, sendo um deles também produtor rural, que relataram quais necessidades deveriam ser atendidas pelo projeto.

O SYSCONBOV possui dois tipos de usuários: administradores e usuários (produtores e gestores de propriedades rurais), que possuem acesso à ferramenta após autenticação por meio de login e senha. Na área administrativa, o administrador pode cadastrar novos usuários, alterar senha (caso algum usuário esqueça), ativar e desativar usuários. Para um melhor controle dos VANTS, é possível realizar cadastro, alteração, remoção e listagem. Futuramente essas informações podem ser utilizadas para calibragem do serviço de contagem que estará executando no servidor. Nesta área também é possível gerenciar os usuários que atuarão como administradores do sistema, acompanhar o status do processamento das imagens enviadas pelos usuários e emitir relatórios sobre o processamento das imagens.

Na área dos usuários é possível realizar o *upload* de imagens de uma determinada propriedade e acompanhar o processamento das imagens enviadas em tempo real. Para isso, na ferramenta é possível gerenciar as propriedades, ou seja, o usuário pode cadastrar, alterar, listar e excluir conforme sua necessidade. Há também a possibilidade de emissão de relatórios com os dados das imagens processadas. Para uma melhor autonomia, a ferramenta também possibilita que o usuário altere suas informações pessoais.

Os usuários podem avaliar a ferramenta por meio de um questionário que contém um conjunto de questões para medir a satisfação do usuário, que contemplam as seguintes medidas que podem estimar a eficácia, eficiência e satisfação do usuário segundo Filardi e Traina (2008): reação ao sistema, tela, terminologia e informação do sistema, aprendizado e capacidade do sistema.

As medidas de eficácia estão diretamente associadas a acurácia e totalidade com que os usuários alcançam objetivos específicos. Já a eficiência está associada ao nível de eficácia obtido nos gastos dos recursos, como esforço mental ou físico, tempo, financeiro ou custos materiais. A satisfação está associada a uma resposta do usuário na interação com o produto (CAMILO *et al.*, 2012).

Para facilitar a indicação da resposta de cada questão do questionário de satisfação pelo usuário e diminuir a subjetividade, foram estabelecidas escalas de Likert com cinco

níveis, conforme o contexto de avaliação de cada questão. Por exemplo, a questão “Estou satisfeito com o software apresentado” está associada a uma escala de Likert com os seguintes níveis: I-discordo totalmente, II-discordo, III-indiferente (ou neutro), IV-concordo e V- concordo totalmente

Os requisitos funcionais e não-funcionais da ferramenta estão descritos no Apêndice A. Para uma melhor visualização dos requisitos, na Figura 13 é apresentado o diagrama de casos de uso correspondente.




Figura 13 – Diagrama de Caso de Uso da Ferramenta SYSCONBOV.

3.5.2 Projetar Arquitetura, Implementar e Implantar Ferramenta

O modelo arquitetural utilizado para projetar a ferramenta SYSCONBOV foi o cliente-servidor, na qual um computador interligado por uma rede a outro computador pode requisitar um serviço e o servidor responde este serviço (COULOURIS, *et al*, 2013). Mais especificamente, foi utilizada a variante cliente-magro desse modelo pois todo o processamento é realizado no servidor.

Na Figura 14 é apresentada a arquitetura da ferramenta por meio do diagrama de implantação da UML (Unified Modeling Language). Nesta figura observa-se que tanto o administrador como o usuário interagem com a ferramenta SYSCONBOV utilizando apenas um navegador (disponível em um computador com acesso à Internet). O servidor web e o servidor de serviços se comunicam, e ambos compartilham o mesmo banco de dados o que permite salvar a contagem no servidor de serviços diretamente no banco de dados, por fim o servidor web consulta a imagem processada.




Figura 14 – Visão geral da arquitetura da ferramenta SYSCONBOV.

O projeto do banco de dados está apresentado no diagrama entidade-relacionamento apresentado na Figura 15 e foi utilizado como base para implementar as tabelas do banco de dados da solução proposta.




Figura 15 – Diagrama entidade-relacionamento do banco de dados da SYSCONBOV.

Para o desenvolvimento da aplicação Web foi utilizada a linguagem PHP. A linguagem Python foi utilizada para o desenvolvimento do software de contagem e o Sistema de Gerenciamento de Banco de Dados (SGBD) MySQL foi utilizado para o armazenamento das imagens, do resultado da contagem e dos cadastros de propriedades e usuários.

O desenvolvimento das páginas web em PHP foram feitas no Notepad ++ na versão ‘7.3’. O Notepad++ é um editor de texto e de código fonte de código aberto sob a licença GPL, que permite a programação em diversas linguagens diferentes, auxiliando na estruturação e codificação.

A escolha da linguagem de programação PHP com SGBD MySQL foi devido a familiaridade e domínio do autor, e por estas tecnologias já estarem implantadas nos servidores da Embrapa Gado de Corte. A utilização da linguagem Python foi selecionada por ser a tecnologia mais utilizada no meio acadêmico para desenvolvimento de sistemas para visão computacional (BOGDANCHIKOV et. al, 2013). Salienta-se que o serviço de contagem e a SYSCONBOV possuem código-fonte aberto.

A implantação da SYSCONBOV está sendo providenciada em um dos servidores da Embrapa Gado de Corte em conjunto com a sua equipe de Tecnologia da Informação.

3.5.3 Exemplo de Uso

Para a utilização da solução proposta⁹, segue um exemplo de uso de algumas telas, como as telas “Cadastro de imagem para contagem”, “Lista de Processamento” com visualização das contagens e do módulo “Administrativo”.

A tela “Cadastro de imagem para contagem” dos bovinos da SYSCONBOV, apresentada na Figura 16, contém os seguintes campos: seleção da propriedade, nome da pastagem ou invernada, tipo de manejo, categoria animal, altura do voo que as imagens foram adquiridas, o tipo de drone e a data que as imagens foram capturadas.

Figura 16 – Tela de Cadastro da Imagem para Processamento do SYSCONBOV.

Por meio da tela “Lista de imagens cadastradas” pode-se visualizar todas as imagens cadastradas pelo usuário, onde consta o número da imagem, a propriedade, o pasto, a data de inserção da imagem, a situação “Processado ou À Processar”, o número de animais contados na imagem e o número de animais validados pelo usuário (se for o caso), os botões de ação visualizar a imagem enviada e visualizar a imagem com a contagem, conforme ilustrado na Figura 17.

⁹ Disponível na URL: <https://sisconbov.cnpgc.embrapa.br>

The screenshot displays the SYSCONBOV web application interface. A modal window titled "Número de Animais Contados: 5" is open, showing an aerial image of a field with several white animals (likely sheep or goats) marked with red bounding boxes. Below the image, there is a text input field labeled "Quantidade Correta de Animais:" with the value "5" entered. At the bottom of the modal are two buttons: "Enviar validação" and "Fechar".

In the background, the main application interface is visible. On the left is a sidebar menu with options: "Painel Principal", "Propriedades", "Imagens", "Inserir", "Listar", "Meus Dados", "Relatórios", and "Avaliação do Sistema". The main area shows a table titled "Lista de Imagem" with columns "Ação" and "Imagem". Below the table are icons for "Imagem Enviada", "Imagem Processada", and "Contar". On the right side, there is a table with the following data:

Situação	Contagem	Validação
Processado	5	5
Processado	7	21
Processado	5	5
Processado	7	7
Processado	7	8
Processado	6	6
Processado	6	6
Processado	5	5
Processado	7	7
Processado	18	20
Processado	11	0
Processado	11	0
Processado	20	20
Processado	32	0
Processado	5	5
Processado	11	40
Processado	18	26

Figura 17 – Tela de Lista de Imagem Cadastradas do SYSCONBOV.

Na área Administrativa, os usuários com o perfil apropriado poderá acessar a tela principal que contém um informativo com o número total de imagens cadastradas na ferramenta, o número de imagens à processar e o número de imagens processadas, um gráfico de quantidade de propriedades por estado e a opção de exibir relatório das imagens processadas, conforme apresentado na Figura 18.




Figura 18 – Área Administrativa do SYSCONBOV.

Está disponibilizado para todos os usuários um questionário para avaliação da satisfação do usuário, que contém 10 questões com temas sobre as telas, as imagens, a confiança, e a velocidade da ferramenta, conforme apresentado na Figura 19.

Questionário de Satisfação do Usuário

Item	Escala
1. Entendimento das telas do sistema.	Difícil ★★★★★ Fácil
2. Termos utilizados nas telas do sistema.	Confuso ★★★★★ Claro
3. Feedback do sistema sobre o que está sendo feito.	Nunca ★★★★★ Sempre
4. Aprendizagem para operar o sistema.	Difícil ★★★★★ Fácil
5. Rapidez na execução das tarefas.	Nunca ★★★★★ Sempre
6. Utilização de sequência lógica na execução das tarefas.	Nunca ★★★★★ Sempre
7. Confiabilidade do sistema.	Nunca ★★★★★ Sempre
8. Velocidade do sistema.	Lento ★★★★★ Boa
9. Localização das imagens nas telas.	Confusa ★★★★★ Clara
10. Tamanho das imagens.	Inadequado ★★★★★ Adequado

Descrição da Avaliação

Figura 19 – Questionário de Satisfação do Usuário da SYSCONBOV.

3.5.4 Testar

A ferramenta SYSCONBOV foi disponibilizada para dois especialistas em nutrição animal (sendo um deles produtor) realizar teste de aceitação e fornecer feedback sobre a satisfação em utilizar a ferramenta, por meio de questionário específico disponível na mesma e detalhado anteriormente na Seção 3.5.1. Salienta-se que indiretamente o serviço de

contagem também foi validado durante os testes. Os avaliadores puderam anotar sugestões de melhorias na ferramenta em um campo do questionário, destinado para isso.

A Figura 20 apresenta um gráfico contendo os resultados do questionário de satisfação respondido pelos especialistas, onde a pontuação de cada questão é demarcada de 0 a 5, do círculo mais interno para o mais externo. Observa-se que a ferramenta foi avaliada para a maior parte das questões como boa ou excelente. Somente na questão 3 um dos avaliadores indicou que não era informado suficiente por suas ações na ferramenta.

A Tabela 5 apresenta as sugestões de melhorias da ferramenta indicadas por cada avaliador no questionário de satisfação. Em geral, declararam que a ferramenta é de fácil manuseio, mas não muito intuitiva. Como principal sugestão de melhoria apontada foi que como o processo de contagem de animais é automatizado, não há necessidade de uma ação do usuário específica para solicitar a contagem, devendo ser realizada automaticamente logo após a inserção da imagem pelo usuário. Essa sugestão de melhoria foi incorporada na última versão da ferramenta, após a avaliação, uma vez que é extremamente relevante para tornar a ferramenta mais intuitiva.




Figura 20 – Resultado do Questionário de Satisfação do Usuário da SYSCONBOV.

Tabela 5 – Melhoria da ferramenta indicadas pelos avaliadores.

Avaliador	Melhorias
Pesquisador 1	Não intuitivo. Dar opção de recarregar imagem e processar na sequência. Não consegui colocar o valor da validação.
Pesquisador 2	Validar a imagem (contar) - para que fosse automático. Acho que a confiabilidade será alcançada com a evolução da IA.

Fonte: Elaborada pelo autor.

3.6 Trabalhos Relacionados

Nove trabalhos relacionados foram selecionados a partir de um mapeamento sistemático conduzido pelo autor no período de 29/08/2018 a 31/10/2018 (Weber *et al.*, 2019) e outros cinco trabalhos foram obtidos posteriormente, a partir de pesquisas em base digitais relevantes, totalizando 14 estudos de interesse. Foram extraídas informações básicas sobre cada estudo, como título, autores, ano de publicação, tipo de publicação e país de afiliação do primeiro autor, conforme apresentadas na Tabela 6.

Tabela 6 – Lista de trabalhos relacionados

Sigla	Citação	Tipo	País
SDIR1	Kellenberger <i>et al.</i> (2018)	Journals	Holanda
SGOO1	Barbedo and Koenigkan (2018)	Journals	Brasil
SGOO2	Sadgrove <i>et al.</i> (2018)	Journals	Reino Unido
SGOO3	Rivas <i>et al.</i> (2018)	Journals	Espanha
SNW1	Andrew <i>et al.</i> (2017)	Conference	Itália
SNW2	Chamoso <i>et al.</i> (2014)	Workshops	Suíça
SNW3	Jung and Ariyur (2017)	Journals	Coreia
SNW4	Nyamuryekung'e <i>et al.</i> (2017)	Journals	USA
SNW5	Trumbull and Myrtle (2017)	Patente	USA
NEW1	Xu <i>et al.</i> (2020)	Journals	USA
NEW2	Li and Xing (2020)	Journals	Áustria
NEW3	Shao <i>et al.</i> (2019)	Journals	França
NEW4	Barbedo <i>et al.</i> (2020)	Journals	Suíça
NEW5	RahnerMoonFar <i>et al.</i> (2019)	Journals	Suíça

Fonte: Elaborada pelo autor.

Nota-se que nos últimos dois anos ocorreu um crescimento significativo no número de artigos publicados representando 64% (9 de 14) do total de trabalhos relacionados identificados. Uma justificativa para isso refere-se a facilidade de aquisição de um VANT, tornando-se cada vez mais acessível, permitindo assim maior número de pesquisas e, conseqüentemente, uma maior aplicabilidade. A maioria dos estudos foi publicada em revistas (78,5%), destacando a originalidade e a maturidade do tema. Considerando a afiliação dos autores, a maioria dos artigos (64%) é da Europa. Brasil e Coréia do Sul

possuem um trabalho cada (7%) e os Estados Unidos possuem dois (14%), sendo um deles patente. Adicionalmente, foram coletadas informações específicas, como as tecnologias e algoritmos de visão computacional empregados, o tipo de solução oferecida pelo estudo e a quantidade de imagens consideradas para aplicação de sua pesquisa. Essas informações sobre cada estudo podem ser observadas na Tabela 7.

Conforme observado na Tabela 7, os trabalhos tratam de problemas relacionados a contagem (50%), reconhecimento/identificação (21%), localização (7%), comportamento (7%) de bovinos e acompanhamento da saúde animal (7%). Nota-se que a maioria dos estudos preocupa-se com a contagem e com a identificação de animais, uma vez que essas atividades são rotineiras nas fazendas e exigem o dispêndio de tempo e, consequentemente, custo principalmente em fazendas com grandes áreas e que lidam com pecuária extensiva.

Tabela 7 – Relação de técnicas, problemas e quantidade de imagem por estudo

Sigla	Citação	Técnica e tecnologia adotadas	Problema Tratado	Qtd de Imagem
SDIR1	Kellenberger <i>et al.</i> (2018)	CNN - Resnet18	Contagem	
SGOO1	Barbedo and Koenigkan (2018)	Algoritmos Rasos (KNN, SVM)	Identificação	
SGOO2	Sadgrove <i>et al.</i> (2018)	Máquina de Aprendizado Extrema de Recurso de Cor e Máquina de Aprendizado Extrema de Múltiplas Cores.	Identificação	
SGOO3	Rivas <i>et al.</i> (2018)	CNN - MLP	Contagem	1200
SNW1	Andrew <i>et al.</i> (2017)	R-CNN - VGG-M 1024	Identificação	11000
SNW2	Chamoso <i>et al.</i> (2014)	CNN	Contagem	N x 40
SNW3	Jung and Ariyur (2017)	Utilização de sensores e dados por satélite	Condução dos animais	
SNW4	Nyamuryekung'e <i>et al.</i> (2017)	Análise visual	Comportamento	4893
SNW5	Trumbull and Myrtle (2017)	Análise visual de vídeos	Localização	
NEW1	Xu <i>et al.</i> (2020)	Mask R-CNN - Bovinos	Contagem	750
NEW2	Li and Xing (2020)	Mask R-CNN - Livestock	Contagem	1000
NEW3	Shao <i>et al.</i> (2019)	K-Means Clustering	Monitoramento	-
NEW4	Barbedo <i>et al.</i> (2020)	CNN - YOLOv2	Contagem	656
NEW5	Rahnemoonfar <i>et al.</i> (2019)	CNN - Mask	Contagem	2679

Fonte: Elaborada pelo autor.

A principal lacuna observada em todos os artigos é a falta de uma ferramenta que possa ser utilizado por usuário fora da academia, que tenham uma maior participação que disponibilizem os pesos para validação e utilização em outras pesquisas. Desse modo o desenvolvimento da ferramenta proposta por este trabalho vem complementar e auxiliar pesquisadores na área da pecuária de precisão e manejo de animais e pecuaristas, utilização de uma CNN para contagem de bovinos.

3.7 Considerações Finais

Neste capítulo foi apresentada a metodologia utilizada para produzir a solução de um software que atenda tanto às necessidades do produtor rural no envio e no resultado da contagem de animais da raça Nelore de imagens adquiridas por VANT's bem como às necessidades da Embrapa Gado de Corte.

Para isso, foram definidas atividades para adquirir imagens, treinar e validar a rede YOLOv5, utilizada neste trabalho, para reconhecer os bovinos Nelore nas imagens. Também foram definidas atividades de processo de desenvolvimento de software para a construção do serviço de contagem e da ferramenta SYSCONBOV. Em especial, as atividades relacionadas ao levantamento de requisitos e à validação da ferramenta desenvolvida foram conduzidas com o apoio de dois especialistas da Embrapa Gado de Corte, que atestaram a sua utilidade e usabilidade. O arquivo com o modelo de pesos da rede proposta pode ser substituído por outro arquivo, dessa forma a SYSCONBOV pode funcionar independentemente do modelo de CNN escolhida.

Como principais desafios encontrados durante a realização deste trabalho destacam-se a dificuldade para aquisição de imagens junto aos pecuaristas e o deslocamento até as fazendas sem apoio financeiro. Outra dificuldade são as anotações nas imagens, que conforme a arquitetura da CNN utilizada, as anotações podem ser diferentes, contudo, todas necessitam ser exatas e demandam bastante tempo para serem definidas. A definição da arquitetura para reconhecimento de objetos e a seleção dos modelos mais adequados para o contexto do trabalho foram outros desafios encontrados, pois necessitam de conhecimento teórico e prático significativos.

4. CONCLUSÃO

4.1 Considerações Iniciais

Neste capítulo, é apresentada a conclusão deste trabalho de mestrado em computação aplicada. Na Seção 4.2, são discutidas as contribuições do trabalho. Na Seção 4.3, são descritas as suas limitações. Na Seção 4.4, são sugeridas indicações de trabalhos futuros para aprimoramento e evolução do trabalho realizado. Por fim, na Seção 4.6, são citadas as produções científicas publicadas, submetidas e previstas.

4.2 Contribuições

O trabalho apresentado nesta dissertação de mestrado facilita e agiliza a contagem de bovinos da raça Nelore em imagens capturadas por VANTs, possibilitando que os pecuaristas obtenham o inventário do rebanho sem esforço e a qualquer momento. Essa contagem automatizada, de baixo custo e na qual os animais permanecem livres para circulação em seu habitat, permite aos pecuaristas saberem o número de animais em determinado lote ou piquete, permitindo corrigir o extravio destes ou trocas de animais entre lotes. Além disso, como não é necessário o manejo dos animais para a contagem do rebanho, o trabalho desenvolvido também colabora para o bem-estar animal.

Uma contribuição deste trabalho é a abordagem definida que tratou: (i) da aquisição de imagens de bovinos da raça Nelore, (ii) da anotação nas imagens destacando os bovinos existentes, (iii) do treinamento e validação de uma rede CNN, em particular do tipo YOLOv5, e (iii) da utilização dos pesos gerados pela rede. A rede obtida alcançou eficiência de 96% para o mAP@.5. Outras contribuições do trabalho são a construção de um serviço Web desenvolvido com base nos pesos gerados pela rede, que retorna a quantidade de animais presentes em uma imagem posteriormente gravando uma nova imagem com os bovinos anotados, e a construção de uma aplicação Web (ferramenta SYSCONBOV) que utiliza esse serviço para automatizar a contagem dos bovinos a partir do envio das imagens do rebanho adquiridas via VANTs pelos pecuaristas ou administradores das propriedades. Outras contribuições indiretas são o documento de requisitos completo da SYSCONBOV, que contém a descrição das necessidades de pesquisadores da Embrapa e de produtores, bem como a definição de um questionário de avaliação de usabilidade e satisfação do usuário que foi incorporado na SYSCONBOV.

Outras contribuições deste trabalho são: a validação dos quatros modelos utilizando a arquitetura da YOLOv5 na contagem de bovinos; disponibilização de uma ferramenta que

possibilita novos treinamento no peso da CNN, melhorando sua acurácia com o passar do tempo.

Ademais, este trabalho pode ser considerado precursor dentro do grupo de Tecnologias Computacionais para Agricultura e Pecuária, e colabora tanto com o estado da prática quanto com o estado da arte uma vez que os trabalhos relacionados que foram encontrados na literatura, não disponibilizam uma ferramenta computacional útil para os usuários finais e não utilizam a versão mais recente da CNN YOLO.

4.3 Limitações

Com empenho de estreitar os pontos de vista da teoria e da prática na aplicação de uma ferramenta para a contagem de bovinos, pode-se listar algumas limitações do trabalho decorrentes da atividade de coleta das imagens, tais como: (i) imagens coletadas somente em dois horários, não cobrindo todas as possibilidades de iluminações e condições meteorológicas, (ii) imagens adquiridas contendo apenas bovinos da raça Nelore, não considerando tamanho e cor da textura de diferentes raças de bovinos; (iii) imagens capturadas em apenas quatro alturas 20, 40, 80 e 100 metros e, em alturas que estiverem fora dessa faixa, a contagem não funcionará adequadamente, (iv) imagens obtidas considerando apenas um tipo de sistema de produção de bovinos, ou seja, confinamento em que todos os animais ficam distribuídos separadamente por baias; (v) quantidade reduzida de imagens contemplando tanto bovinos oclusos por algum tipo de vegetação quanto bovinos muito próximos do outro, tornando insuficientes para generalizar para todos os casos; e (vi) como a contagem está sendo feita em uma única imagem, há limitação da abrangência de um único lote ou piquete.

Uma limitação técnica mais específica está relacionada a implementação dos algoritmos para treino dos pesos da rede, pois apenas uma arquitetura de CNN foi considerada neste trabalho. Outra limitação está relacionada a ferramenta SYSCONBOV, uma vez que alguns requisitos funcionais não foram incorporados em sua primeira versão, tais como: módulo de anotação das imagens na ferramenta SYSCONBOV, criação de relatórios diversos, cálculo do GSD com base na altura e definição do sensor do VANT, verificação da qualidade da imagem antes de fazer o processamento de contagem, subdivisão das imagens em quadrantes de interesses e contagem de animais da raça Nelore por quadrante, e verificar a limitação do algoritmo utilizado com relação a diferentes GSDs.

4.4 Trabalhos Futuros

O trabalho desenvolvido possibilitará novas pesquisas, que podem contribuir para a área de pecuária de precisão, monitoramento de bovinos, zootecnia e a medicina veterinária. Dessa forma, a seguir estão elencadas algumas sugestões de trabalhos futuros:

- Aprimorar o banco de imagens existente considerando diferentes raças de bovinos, condições climáticas, sistemas de produção, alturas de captura, quantidade maior de bovinos oclusos e sobrepostos; em seguida, treinar e validar a rede CNN para aumentar a acurácia do reconhecimento dos bovinos nas imagens e, consequentemente, a acurácia na detecção dos bovinos;
- Treinar e validar outras redes CNN com base no banco de imagens atualizado e observar a acurácia na detecção de bovinos de cada uma delas a fim de incorporar a mais adequada na SYSCONBOV;
- Especificar, projetar, implementar e testar um módulo de anotação na ferramenta SYSCONBOV, que disponibilize uma funcionalidade de marcação on-line dos bovinos não identificados nas imagens, assim disponibilizando novos objetos de interesse para treino da CNN, aproveitando os pesos já existentes. Fazer a contagem e reconhecimento de bovinos que estão em pé ou em ócio (caracterizado por animais deitados);
- Projetar, implementar e testar outros relatórios na SYSCONBOV, como: quantitativo de bovinos por área, quantitativo de bovinos em pé ou em ócio, bem como outros relatórios que podem ser levantados pelos stakeholders; e
- Integrar o banco de dados da SYSCONBOV com o banco de dados de usuários dos aplicativos da Embrapa para efetuar cadastro e login de usuário únicos;
- Subsidiar a construção de banco de dados do rebanho nacional;
- Aprimorar o recebimento de várias imagens de um único lote, possibilitando a junção das mesmas utilizando técnicas específicas para isso, como é o caso de ortomosaicos;
- Redução do tamanho da imagem antes do envio para o servidor a fim de otimizar o carregamento das imagens;
- Planejamento e execução de testes de estresse na ferramenta SYSCONBOV;
- Disponibilizar toda informação cadastrada na SYSCONBOV conforme a Lei Geral de Proteção de Dados Pessoais (LGPD) nº 13.709, aprovada em agosto de 2018 e com vigência a partir de agosto de 2020.

4.5 Produção Científica

A seguir estão elencados a publicação obtida referente ao mapeamento sistemático conduzido no âmbito deste trabalho e outros dois artigos técnico-científicos que serão escritos e submetidos a veículos de publicação relevantes da área.

- WEBER, F. L.; CAGNIN, M. I.; PAIVA, D. M. B.; WEBER, V. A. M.; PISTORI, H.; MEDEIROS, S. R.; GOMES, R. C. “Use of computational vision and UAVs in livestock: a Literature review”, 14th Iberian Conference on Information Systems and Technologies (CISTI), Coimbra, Portugal, 2019, pp. 1-7, doi: 10.23919/CISTI.2019.8760955. 2019.
- Weber *et al.* “Cattle segmentation using uavs supported by computer vision techniques: Preliminary results”, IV Congresso Internacional Proceedings of GRSS-YP & YSPRS Student Consortium Summer School, 28 de outubro de 2018 a 01 de novembro de 2018, ISBN 978-85-7613-582-1, Editora UFMS. 2018.
- WEBER, F. L. *et al.* Counting Cattle in Images from Unmanned Aerial Vehicle using YOLOv5. A ser submetido no Workshop de Visão Computacional 2020 (WCV) ou na revista Computer Electronics and Agriculture.
- WEBER, F. L. *et al.* SYSCONBOV - Sistema de contagem de bovinos utilizando imagens adquiridas por VANT's. A ser submetido na Revista Eletrônica de Sistemas de Informação (RESI) ou no Congresso Brasileiro de Agroinformática (SBIAgro).

Outros trabalhos indiretamente relacionados a este trabalho de mestrado foram publicados¹, submetidos² ou capítulo de livro³:

¹WEBER, V. A. M.; WEBER, F. L.; OLIVEIRA JUNIOR, A. S.; BELETE, N. A. S.; GOMES, R. C.; ABREU, U. G. P.; PISTORI, H. Prediction of Girolando cattle weight by means of body measurements extracted from images. Revista Brasileira de Zootecnia, v. 49, p. 1-15, 2020. doi: <10.37496/rbz4920190110>

¹WEBER, F. L.; WEBER, V. A. M.; MENEZES, G. V.; OLIVEIRA JUNIOR, A. S.; ALVES, D. A.; OLIVEIRA, M. V. M. MATSUBARA, E. T.; PISTORI, H.; ABREU, U. G. P. Recognition of Pantaneira cattle breed using computer vision and convolutional neural networks. Computers and Electronics in Agriculture, v. 175, p. 105548, 2020.

¹JUSSIANI, V. B.; WEBER, V. A. M.; WEBER, F. L.; FERREIRA, A. S.; DA SILVA, G. G.; PICOSSE, F.; BAGATIN, E.; PISTORI, H. Software for Automatic Evaluation of Stretch Marks. 14th Iberian Conference on Information Systems and

Technologies (CISTI), Coimbra, Portugal, 2019, pp. 1-6, 2019. doi: <10.23919/CISTI.2019.8760880>

¹WEBER, V. A. M.; WEBER, F. L.; SILVEIRA, E.; OLIVEIRA, G. L.; FOLHES, M.; CONSTANTINO, M.; PISTORI, H.. Determination of number of termite mounds supported by computational vision. In: WORKSHOP DE VISÃO COMPUTACIONAL (WVC), 15. , 2019, São Bernardo do Campo. Anais do XV Workshop de Visão Computacional. Porto Alegre: Sociedade Brasileira de Computação, p. 85-90, 2019. doi: <10.5753/wvc.2019.7633>

¹WEBER, V. A. M.; WEBER, F.L.; JUNIOR, A. S. O.; ASTOLFI, G.; BONIN, M. N.; ITAVO, L. C. V.; LEAL, E. S.; MARCATO JUNIOR, J.; SALGADO FILHO, G. R.; PISTORI, H. “Prediction Of Live Weight Of Cattle Using Uavs: Preliminary Results”, IV Congresso Internacional Proceedings of GRSS-YP & YSPRS Student Consortium Summer School, 28 de outubro de 2018 a 01 de novembro de 2018, ISBN 978-85-7613-582-1, Editora UFMS. 2018.

²WEBER, V. A. M.; WEBER, F.L.; MENEZES, G. V.; JUNIOR, A. S. O.; ASTOLFI, G.; PORTO, J. V.; REZENDE, F. P.; MORAES, P. H.; MATSUBARA, E. T.; MATEUS, R. G.; ARAUJO, T. L.; SILVA, L. O . C.; QUEIROZ, E. Q.; GOMES, R. C.; PISTORI, H. Cattle Weight Estimation Using Active Contour Models and Regression Trees Bagging. Computers and Electronics in Agriculture, 2020.

²JUNIOR, A. S. O.; WEBER, V. A. M.; ASTOLFI, G.; WEBER, F. L.; MENEZES, G. V.; MENEZES, G. K.; ALBUQUERQUE, P. L. F.; COSTA, C. S.; GARCIA, V.; SANT’ANA, D. A.; PACHE, M. C. B.; QUEIROZ, E. Q. A.; ROZALES, J. V. A.; FERREIRA, M. W.; NAKA, M. H.; PISTORI, H. Fingerlings mass estimation: a comparison between deep and learning algorithms, Computers and Electronics in Agriculture, 2020.

²WEBER, V. A. M; ALBUQUERQUE, P; WEBER, F. L.; MATEUS, R. G.; ARRUDA, C. O. C. B.; PIVA, R.; GOMES, R. C.; SILVA, G. G.; SILVA, S. S.; PISTORI, H. An analysis tool for cattle frequency in feed bunk supported by Computer Vision: Preliminary Results. In: WORKSHOP DE VISÃO COMPUTACIONAL (WVC), 16. Uberlândia-MG. Anais do XV Workshop de Visão Computacional, 2020.

²WEBER, V. A. M; CHAVES, N. R. B.; GARCIA, E. R. M.; WEBER, F. L.; ANDRADE, G. C.; SANTANA, P. G.; ROCHA, B. J., JUNIOR, A. S. O.; ESPEJO, R.; MORAES, P. H.; PISTORI, H. Classification of eggs images acquired by mobile device to identify the storage period of commercial eggs. In: WORKSHOP DE VISÃO COMPUTACIONAL (WVC), 16, Uberlândia-MG. Anais do XV Workshop de Visão Computacional, 2020.

²JUNIOR, A. S. O.; PACHE, M. C. B.; RESENDE, F. P. C.; SANT’ANA, D. A.; WEBER, V. A. M.; ASTOLFI, G.; WEBER, F. L.; MENEZES, G. V.; MENEZES, G. K.

ALBUQUERQUE, P. L. F.; COSTA, C. S.; GARCIA, V.; QUEIROZ, E. Q. A.; ROZALES, J. V. A.; FERREIRA, M. W.; NAKA, M. H.; PISTORI, H. An investigation about the optimization of parameters in a fingerling counting problem. In: WORKSHOP DE VISÃO COMPUTACIONAL (WVC), 16, Uberlândia-MG. Anais do XV Workshop de Visão Computacional, 2020.

³ARAÚJO, R. V.; ESPEJO, R. A.; DA COSTA, R. B.; WEBER, V. A. M.; WEBER, F. L.; CONSTANTINO M.; COSTA R. Eficiência econômica dos maiores municípios do Estado de Goiás utilizando Software R. Sistematizando Práticas para Administrar. 1ed. Ponta Grosso, PR: Atena Editora, p. 59-69. 2019. doi:< 10.22533/at.ed.5601930098>

³ESPEJO, R.; ARAÚJO, R.; CONSTANTINO, M.; COSTA, R.; MORAES, P.; WEBER, V. A. M.; WEBER, F.L.; DOTTO, F. Aplicação da análise envoltória de dados em empresas do setor agroflorestal. As Ciências Exatas e da Terra no Século XXI. 2ed. Ponta Grosso: Atena Editora, p. 58-67, 2019. doi: <10.22533/at.ed.8051907106>

REFERÊNCIAS

- ABIEC. Associação Brasileira das Indústrias Exportadoras de Carnes. Perfil da Pecuária no Brasil: Relatório Anual, Setembro, 2018.
- ABADI, M. ; AGARWAL, A.; BARHAM, P.; BREVDO, E; CHEN, Z.; CITRO, C.; CORRADO, G. S.; DAVIS, A.; DEAN, J.; DEVIN, M.; GHEMAWAT, S.; GOODFELLOW, I.; HARP, A.; IRVING, J.; ISARD, M.; JIA, Y.; JOZEFOWICZ, R.; KAISER, L.; KUDLUR, M.; LEVENBERG, J.; MANE, D.; MONGA, R.; MOORE, S.; MURRAY, D.; OLAH, C.; SCHUSTER, M.; SHLENS, J.; STEINER, B.; SUTSKEVER, I.; TALWAR, K.; TUCKER, P.; VANHOUCHE, V.; VASUDEVAN, V.; VIEGAS, F.; VINYALS, O.; WARDEN, P.; WATTENBERG, M.; WICKE, M.; YU, Y.; ZHENG X. TensorFlow: Large-scale machine learning on heterogeneous systems. Software disponível em < <http://tensorflow.org/>>. Acessado em: 15 de fevereiro de 2019. 2015.
- AMIN, S.; GALASSO, F. Geometric proposals for faster r-cnn. In: 2017 14th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS). IEEE,. p. 1-6. 2017.
- ANDREW, W.; GREATWOOD, C.; BURGHARDT, T. Visual localization and individual identification of Holstein Friesian cattle via deep learning. In: Proc. IEEE International Conference on Computer Vision (ICCV), Venice, Italy. p. 22-29, 2017.
- AL-RFOU, R.; ALAIN, G.; ALMAHAIRI, A.; ANGERMUELLER, C.; BAHDANAU, D.; BALLAS, N.; BASTIEN, F.; BAYER, J.; BELIKOV, A.; BELOPOLSKY, A.; BENGIO, Y.; BERGERON, A.; BERGSTRA, J.; BISSON, V.; SNYDER, J. B.; BOUCHARD, N.; BOULANGER-LEWANDOWSKI, N.; BOUTHILLIER, X.; ZHANG, Y. Theano: A Python framework for fast computation of mathematical expressions. arXiv e-prints, abs/1605.02688, 2016.
- BARBEDO, J. G. A.; KOENIGKAN, L. V. Perspectives on the use of unmanned aerial systems to monitor cattle. Outlook on Agriculture, 47(3), 214–222, 2018.
- BARBEDO, J.G.A.; KOENIGKAN, L.V.; SANTOS, P.M.; RIBEIRO, A.R.B. Counting Cattle in UAV Images—Dealing with Clustered Animals and Animal/Background Contrast Changes. Sensors 2020, 20, 2020.
- BARBOSA, F. A.; SOUZA, R. C. Administração de fazendas de bovinos: leite e corte. Viçosa: Aprenda Fácil, 2007.
- BEYOND, R. G. ANOVA, Basics of Applied Statistics, John Wiley & Sons: New York. 1986.

- BERCOVICH, A., EDAN, Y., ALCHANATIS, V., MOALLEM, U., PARMET, Y., HONIG, H., MALTZ, E., ANTLER, A., HALACHMI, I., 2013. Development of an automatic cow body condition scoring using body shape signature and Fourier descriptors. *J. Dairy Sci.* 96 (12), p. 8047–8059, 2013.
- BERRY, R. J.; KENNEDY, A. D.; SCOTT, S. L.; KYLE, B. L.; SCHAEFER, A. L. Daily variation in the udder surface temperature of dairy cows measured by infrared thermography: Potential for mastitis detection. *Canadian Journal of Animal Science.* v.83 (4), p. 687-693, 2003.
- BOGDANCHIKOV, A.; ZHAPAROV, M.; SULIYEV, R. Python to learn programming. In: *Journal of Physics: Conference Series.* IOP Publishing. p. 012027, 2013.
- BOCHKOVSKIY, A.; WANG, C.; LIAO, H. M. YOLOv4: Optimal Speed and Accuracy of Object Detection. *arXiv preprint arXiv:2004.10934*, 2020.
- BORTH, M.; RIBAS, L.; PISTORI, H.; GONÇALVES, W.; DE CASTRO JÚNIOR, A.A. Classificação de Espécies de Peixe usando Inferência Gramatical no Reconhecimento de Padrões em Problemas de Visão Computacional. *WTA – Workshop de Tecnologia Adaptativa*, São Paulo. 2016.
- BORTOLUZZO, A. B.; PEDRINOLA, P. D.; MARTINS, S. R. Tempo Ideal Para Abate de Gado de Corte Via Maximização do Lucro. *Ibmec Working Papers*, 2011.
- BOSER, B. E.; GUYON, I. M.; VAPNIK, V. N. A training algorithm for optimal margin classifiers. In: *Proceedings of the fifth annual workshop on Computational learning theory.* ACM, p. 144-152, 1992.
- BRASIL. Força Aérea esclarece normas para voos de drones no Brasil. Disponível em: <<http://www.brasil.gov.br/noticias/seguranca-e-justica/2015/03/forca-aerea-esclarece-normas-para-voos-de-drones-no-brasil>>. Acesso em: 26 de novembro de 2018. 2015.
- CÁCERES, E. N.; PISTORI, H.; TURINE, M. A. S.; PIRES, P. P.; SOARES, C. O.; CARROMEU, C. Computational precision livestock-position paper. II Workshop of the Brazilian Institute for Web Science Research, nº 02-03, p. 9, 2011.
- CAJA, G.; CASTRO-COSTA, A.; KNIGHT, C. H. Engineering to support wellbeing of dairy animals. *Journal of Dairy Research*, v. 83, p. 136-147, 2016.
- CHAMOSO, P.; RAVEANE, W.; PARRA, V.; GONZÁLEZ, A. UAVs Applied to the Counting and Monitoring of Animals. *Advances in Intelligent Systems and Computing.* 291. 10.1007/978-3-319-07596-9_8, 2014
- COHN, A. S.; MOSNIER, A.; HAVLÍK, P.; VALIN, H et al. Cattle ranching intensification in Brazil can reduce global greenhouse gas emissions by sparing land from deforestation. *Proceedings of the National Academy of Sciences of the United States of America*, v. 111, n. 20, p. 7236- 7241, 2014.

- COLLOBERT, R.; KAVUKCUOGLU, K.; FARABET, C. Torch7: A matlab-like environment for machine learning. Em BigLearn, NIPS Workshop. 2011.
- CORTIVO, P. D., DIAS, E., BARCELLOS, J. O. J., PERIPOLLI, V., COSTA JR, J. B. G., DAL-LAGO, B. S. L., MCMANUS, C. M. Use of thermographic images to detect external parasite load in cattle. *Computers and Electronics in Agriculture* 127, 413–417, 2016.
- COSTA, D. D. S.; TURCO, S. H.; RAMOS, R. P.; SILVA, F. M.; FREIRE, M. S. Electronic monitoring system for measuring heart rate and skin temperature in small ruminants. *Engenharia Agrícola*, 38(2), p. 166-172, 2018.
- COULOURIS, G.; DOLLIMORE, J.; KINDBERG, T.; BLAIR, G. *Sistemas Distribuídos: Conceitos e Projeto*. Bookman Editora, 2013.
- COVER, T. M.; HART, P. E. Nearest Neighbor Pattern Classification. *IEEE Transactions on Information Theory*, 13, 21-27, 1967.
- DA SILVA, I. J. O. Automação dos sistemas para aumento do conforto animal. NUPEA, ESALQ - USP. Disponível em: <<http://www.nupea.esalq.usp.br/admin/modSite/arquivos/imagens/857de97217f133bbcc4b48b3db797a68.pdf>>. Acesso em: 12 de dezembro de 2018. 2001.
- DA SILVA, D. G.; FLORIT, L. F. Notas sobre as implicações socioeconômicas, ambientais e éticas da ocupação do território e a transformação da paisagem pela pecuária no Brasil. *Anais: Seminário de Desenvolvimento Regional, Estado e Sociedade*, v. 1, n. 1, 2013.
- DALAL, N. and TRIGGS, B. Histograms of oriented gradients for human detection. In *CVPR*, 2005.
- DE GRAAF, S.; VAN LOO, E.; BIJTTEBIER, J.; VANHONACKER, F.; LAUWERS, L.; TUYTTENS, F.; VERBEKE, W. Determinants of consumer intention to purchase animal-friendly milk. *Journal of dairy science*, v. 99, n. 10, p. 8304-8313, 2016.
- DEBIASI, L. T.; PERIN, M. V.; ALVES, R. J. F. Protótipo de planador de baixo custo para aplicações na agricultura de precisão. *Unoesc & Ciência-ACET*, 9(1), 59-66, 2018.
- EMBRAPA. Empresa Brasileira de Pesquisa Agropecuária. Pecuária de Precisão em Saúde e Comportamento Alimentar. *Revista Leite Integral*. Disponível em <<https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/1013697/1/Cnppl2014LeiteIntegralPecuaria.pdf>>. Acesso em: 12 de dezembro de 2018. 2014.
- EVERINGHAM, M.; VAN GOOL, L.; WILLIAMS, C. K. I.; WINN, J.; ZISSERMAN, A. The PASCAL Visual Object Classes (VOC) Challenge. *IJCV*, 2010.

- FERREIRA, A. S. F.; FREITAS, D. M.; SILVA, G. G.; PISTORI, H.; FOLHES, M. T. Weed detection in soybean crops using ConvNets. *Computers and Electronics in Agriculture*, v. 143, p. 314-324, 2017.
- JIANG, T.; GELLER, J.; NI, D.; COLLURA, J. Unmanned Aircraft System traffic management: Concept of operation and system architecture. *International journal of transportation science and technology*, 5(3), p. 123-135, 2016.
- JORGE, LA de C.; INAMASU, R. Y. Uso de veículos aéreos não tripulados (VANT) em agricultura de precisão. Embrapa Instrumentação-Capítulo em livro científico (ALICE), 2014.
- FORSYTH, D. A.; PONCE, J. *Computer Vision - A Modern Approach*. Pearson, 2012.
- FUJII, K.; HIGUCHI, K.; REKIMOTO, J. Endless flyer: a continuous flying drone with automatic battery replacement. In: *Ubiquitous Intelligence and Computing, 2013 IEEE 10th International Conference on and 10th International Conference on Autonomic and Trusted Computing (UIC/ATC)*. IEEE, p. 216-223, 2013.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. Cambridge, Massachusetts: MIT Press. 2016.
- GORA, A.; BREZOVSKY, J.; DAMBORSKY, J.. Gates of enzymes. *Chemical reviews*, v. 113, n. 8, p. 5871-5923, 2013.
- GRAML, R., WIGLEY, G. Bushfire hotspot detection through uninhabited aerial vehicles and reconfigurable computing, *Aerospace Conference, 2008 IEEE*. IEEE, pp. 1-13, 2008.
- GIRSHICK, Ross. Fast r-cnn. In: *Proceedings of the IEEE international conference on computer vision*. p. 1440-1448, 2015.
- HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H. The weka data mining software: an update. *ACM SIGKDD explorations newsletter*, 11(1):10–18. 16, 17, 2009.
- HARRIS-BRIDGE, G.; YOUNG, L.; HANDEL, I.; FARISH, M.; MASON, C.; MITCHELL, M. A.; HASKELLTHE, M.J. Use of infrared thermography for detecting digital dermatitis in dairy cattle: What is the best measure of temperature and foot location to use? *The Veterinary Journal*, v. 237, p. 26-33, 2018.
- HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep residual learning for image recognition. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. p. 770-778. 2016.
- HUNG, C.; BRYSON, M.; SUKKARIEH, S. Multi-class predictive template for tree crown detection. *ISPRS journal of photogrammetry and remote sensing*, v. 68, p. 170-183, 2012.

- JAHNE, B.; HAUBECKER, H. Computer vision and applications: a guide for students and practitioners. Academic Press, 2000.
- JIA, Y., SHELHAMER, E., DONAHUE, J., KARAYEV, S., LONG, J., GIRSHICK, R., GUADARRAMA, S., E DARRELL, T. Caffe: Convolutional architecture for fast feature embedding. arXiv preprint arXiv:1408.5093, 2014.
- JOCHER, G.; KWON, Y.; VEITCH-MICHAELIS, J.; KENDALL, D., et al. (2020, May 4). ultralytics/yolov3: 43.1mAP@0.5:0.95 on COCO2014 (Version v7). Zenodo. <http://doi.org/10.5281/zenodo.3785397>, 2020.
- JORGE, LA de C.; INAMASU, Ricardo Y. Uso de veículos aéreos não tripulados (VANT) em agricultura de precisão. Embrapa Instrumentação-Capítulo em livro científico (ALICE), 2014.
- JUNG, S; ARIYUR, B. K. Strategic Cattle Roundup using Multiple Quadrotor UAVs. International Journal of Aeronautical and Space Sciences, v. 18, n. 2, p. 315-326, 2017.
- KELLENBERGER, B.; VOLPI, M.; TUIA, D. Fast animal detection in UAV images using convolutional neural networks. p. 866-869, 2017.
- KUZUHARA, Y., KAWAMURA, K., YOSHITOSHI, R., TAMAKI, T., SUGAI, S., IKEGAMI, M., YASUDA, T. A preliminarily study for predicting body weight and milk properties in lactating Holstein cows using a three-dimensional camera system. Computers and Electronics in Agriculture, 111, 186–193, 2015.
- LAO, F., BROWN-BRANDL, T., STINN, J., LIU, K., TENG, G., XIN, H. Automatic recognition of lactating sow behaviors through depth image processing. Computers and Electronics in Agriculture 125, p. 56–62, 2016.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. Nature, 521(7553), p. 436-444, 2015.
- LEE, H. J.; ROBERTS, S. J.; DRAKE, K. A.; DAWKINS, M. S. Prediction of feather damage in laying hens using optical flows and markov models. J R Soc Interface v. 8, p. 489–499, 2011.
- LOWE, D. Distinctive image features from scale-invariant keypoints. IJCV, 2004.
- LIMA, M. L.; NEGRAO, J. A.; PAZ, C. C. P.; GRANDIN, T. Effect of corral modification for humane livestock handling on cattle behavior and cortisol release (Abstract 68). American Society of Animal Science, 2016.
- LIN, T. Y.; GOYAL, P.; GIRSHICK, R.; HE, K.; DOLLÁR, P. Focal loss for dense object detection. In Proceedings of the IEEE international conference on computer vision (pp. 2980-2988), 2017.

- LIU, T.; ABD-ELRAHMAN, A. Multi-view object-based classification of wetland land covers using unmanned aircraft system images. *Remote sensing of environment*, v. 216, p. 122-138, 2018.
- LUIZ, O. J.; WEBER, V. A.; CAGNIN, M. I.; RAPOSO DE MEDEIROS, S.; GOMES, R. D.; CRISTINE DE SOUZA, L.; PAIVA, D. M. Computational System to Support Bovine Nutritional Behavior. *International Journal of Agricultural and Environmental Information Systems (IJAEIS)*, 9(3), p. 22-37, 2018.
- MACEDO, M. C. M. Integração lavoura e pecuária: o estado da arte e inovações tecnológicas. *Revista Brasileira de Zootecnia*, 38 (Suplemento), 2009.
- MITCHELL, T. M. *Machine Learning*. 1ª Edição. McGraw-Hill, 1997.
- MURPHY, E.; NORDQUIST, R.; VAN DER STAAY, F. J. A review of behavioral methods to study emotion and mood in pigs, *Sus scrofa*. *Applied Animal Behaviour Science*, v. 159, p. 9-28, 2014.
- NASIRAHMADI, A.; RICHTER, U.; HENSEL, O.; EDWARDS, S.; STURM, B. Using machine vision for investigation of changes in pig group lying patterns. *Computers and Electronics in Agriculture*, Volume 119, p. 184-190, 2015.
- NASIRAHMADI, A.; EDWARDS, S. A.; STURM, B. Implementation of machine vision for detecting behaviour of cattle and pigs. *Livestock Science*, v. 202, p. 25-38, 2017.
- NASRABADI, Nasser M. Pattern recognition and machine learning. *Journal of electronic imaging*, v. 16, n. 4, p. 049901, 2007.
- NIXON, M.S.; AGUADO, A.S. *Feature Extraction and Image Processing*. Newnes, Central Tablelands. 2002.
- NYAMURYEKUNG'E, S.; CIBILIS, A. F.; ESTELL, R. E.; GONZALEZ, A. L. Use of an unmanned aerial vehicle– mounted video camera to assess feeding behavior of Raramuri Criollo cows. *Rangeland ecology & management*, v. 69, n. 5, p. 386-389, 2016.
- ORACLE CORPORATION. *MYSQL 8.0 OVERVIEW*. 2019, Disponível em: <https://www.mysql.com/why-mysql/presentations/mysql-80-overview/>>. Acesso em: 10 de agosto de 2019.
- PATRI, R. C. Novas abordagens em aprendizado de máquina para a geração de regras, classes desbalanceadas e ordenação de casos. Tese (Doutorado), ICMC-USP, São Carlos, 2006.
- PLUK, A.; BAHR, C.; POURSAHERI, A.; MAERTENS, W.; VAN NUFFEL, A.; BERCKMANS, D. Automatic measurement of touch and release angles of the fetlock joint for lameness detection in dairy cattle using vision techniques. *Journal of dairy science* 95, p. 1738–1748, 2012.

- PORTO, S. M.; ARCIDIACONO, C.; ANGUZAA, U.; CASCONI, G. A computer vision-based system for the automatic detection of lying behaviour of dairy cows in free-stall barns. *Biosystems Engineering*, v. 115, n. 2, p. 184 – 194, 2013.
- QIN, P.; LI, C.; CHEN, J.; CHAI, R. Research on improved algorithm of object detection based on feature pyramid. *Multimedia Tools and Applications*, 78(1), 913-927. 2019.
- QUINLAN, J. R.; C4.5: Programs for machine learning. Morgan Kaufmann Publishers Inc., San Francisco, CA, USA, 1993.
- QUINTA, L. N. B. Visão Computacional aplicada na classificação de grãos de pólen, 2013. 59 f. Dissertação (Mestrado) — Programa de Pós-Graduação em Biotecnologia da Universidade Católica Dom Bosco. 2013.
- REDMON, J.; DIVVALA, S., GIRSHICK, R.; FARHADI, A. You only look once: Unified, real-time object detection. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 779– 788, 2016.
- REDMON, J. AND FARHADI, A. YOLOv3: An Incremental Improvement. *arXiv*. 2018.
- REDMON, J.; FARHADI, A. YOLO9000: better, faster, stronger. *arXiv preprint arXiv:1612.08242*, 2016.
- REN, S.; HE, K.; GIRSHICK, R.; SUN, J. Faster R-CNN: Towards real-time object detection with region proposal networks. In *Advances in Neural Information Processing Systems (NIPS)*, pages 91–99, 2015.
- RIVAS, A.; CHAMOSO, P.; BRIONES, A. G.; CORCHADO, J. M. Detection of Cattle Using Drones and Convolutional Neural Networks. *Sensors (Basel, Switzerland)*, 18(7), 2048. doi:10.3390/s18072048, 2018.
- SAHA, S.; BANDYOPADHYAY, S. Segmentação de imagens cerebrais por ressonância magnética por técnica de agrupamento genético baseado em simetria fuzzy. 2007 IEEE Congress on Evolutionary Computation, p. 4417-4424, 2007.
- SALAMÍ, Esther; BARRADO, Cristina; PASTOR, Enric. UAV flight experiments applied to the remote sensing of vegetated areas. *Remote Sensing*, v. 6, n. 11, p. 11051-11081, 2014.
- SADGROVE, E. J.; FALZON, G.; MIRON, D.; LAMB, D. W. Real-time object detection in agricultural/remote environments using the multiple-expert colour feature extreme learning machine (MEC-ELM), *Computers in Industry*, Volume 98, p. 183-191, 2018.
- SCHLESINGER, S. Onde pastar?: o gado bovino no Brasil. Rio de Janeiro: Fase. 2010.
- SIEBERT, S; TEIZER, J. Mobile 3D Mapping for Surveying Earthwork Projects Using na Unmanned Aerial Vehicle (UAV) System. *Automation in Construction*, Elsevier Journal, 31 jan. 2014.

- SILVA, R. T. R.; BARCELOS, J. J.; FALCHETTI, S. A. Estudo da aplicação do planejamento estratégico para atividade pecuária bovina de cria, recria e Engorda: um estudo de caso – Fazenda Santa Maria da Amazônia. XIII Simpósio de Administração da Produção, Logística e Operações Internacionais - SIMPOI 2010.
- SHAO, W.; KAWAKAMI, R.; YOSHIHASHI, R.; YOU, S., KAWASE, H.; NAEMURA, T. Cattle detection and counting in UAV images based on convolutional neural networks. *International Journal of Remote Sensing*, 41(1), p. 31-52, 2019.
- SOLANKI, J. *International Journal of Engineering & Science Research*. 2013.
- SOUZA, K. P. Aplicação de modelos de markov ocultos na obtenção de taxas de mortalidade das larvas do mosquito da dengue. Tese (Mestrado), Faculdade de Computação, Universidade Federal de Mato Grosso do Sul. 2010.
- SPOLIANSKY, R.; EDAN, Y.; PARMET, Y.; HALACHMI, I. Development of automatic body condition scoring using a low-cost 3-dimensional Kinect camera. *Journal of dairy science*, v. 99, p. 7714-7725, 2016.
- SZELISKI, R. *Computer Vision: Algorithms and Applications*. Springer, 2010.
- TERLETZKY, Pat A.; RAMSEY, Robert Douglas. Comparison of three techniques to identify and count individual animals in aerial imagery. *Journal of Signal and Information Processing*, v. 7, n. 03, p. 123, 2016.
- TETILA, E.; MACHADO, B.; BELETE, N. A.; GUIMARAES, D. A.; PISTORI, H. identification of Soybean Foliar Diseases Using Unmanned Aerial Vehicle Images. *IEEE Geoscience and Remote Sensing Letters*. p. 1-5, 2017.
- TRUMBULL, T. R.; MYRTLE, S. R. Unmanned livestock monitoring system and methods of use. U.S. Patent Application n. 15/000,018, 20 jul. 2017.
- VAPNIK, V. The support vector method of function estimation. In: *Nonlinear Modeling*. Springer, Boston, MA, p. 55-85, 1998.
- VEDALDI, A. e LENC, K. Matconvnet – convolutional neural networks for matlab. Em *Proceeding of the ACM Int. Conf. on Multimedia*. 2015.
- VIEIRA, A.; LOBATO, J. F. P.; CORRÊA, E. S.; TORRES JÚNIOR, R. A. D. A. e COSTA, F. P. Growth and reproductive performance of grazing females Nellore on cerrado of Central Brazil. *Revista Brasileira de Zootecnia*, 35(1), p. 186-192, 2006.
- XU, B.; WANG, W.; FALZON, G.; KWAN, P.; GUO, L.; SUN, Z.; LI, C. Livestock classification and counting in quadcopter aerial images using Mask R-CNN. *International Journal of Remote Sensing*, 1-22, 2020
- XU, B.; WANG, W.; FALZON, G.; KWAN, P.; GUO, L.; CHEN, G.; SCHNEIDER, D. Automated cattle counting using Mask R-CNN in quadcopter vision system. *Computers and Electronics in Agriculture*, v. 171, p. 105300, 2020.

XUE, Y.; WANG, T.; SKIDMORE, A. K. Automatic Counting of Large Mammals from Very High Resolution Panchromatic Satellite Imagery. *Remote sensing*, v. 9, n. 9, p. 878, 2017.

A. DOCUMENTO DE REQUISITOS

Este apêndice apresenta o Documento de Requisitos da SYSCONBOV.

A – VISÃO GERAL DA FERRAMENTA

A ferramenta SYSCONBOV consiste basicamente na contagem de animais da raça Nelore distribuído em piquetes de propriedades rurais, por meio de cadastro de Produtor, Envio de Imagens do dorso de animais e Resultado da contagem de animais. A ferramenta deve ainda emitir diversos tipos de relatórios e consultas, do ponto de vista dos produtores e dos pesquisadores da Embrapa Gado de Corte.

B – REQUISITOS FUNCIONAIS

B1 – Lançamentos diversos

1. A ferramenta deve permitir a inclusão, alteração e remoção de Propriedade, contendo os seguintes atributos: nome, CNPJ/CPF, Inscrição Estadual, Nome da Propriedade, Local, Área total da propriedade (em hectares), a área destinada a pastos (em hectares).
2. A ferramenta deve permitir a inclusão, alteração e remoção de imagens ou grupo de imagens, contendo os seguintes atributos: Propriedade, pastagem/invernada, altura do voo, tipo de equipamento, tipo do manejo, categoria animal, data das imagens e arquivos das imagens.
3. A ferramenta deve permitir a contagem de bovinos das imagens enviadas pelo produtor. Essa função deve ser executada automaticamente e o resultado deve ser armazenado.
4. A ferramenta deve permitir consulta dos resultados de contagem de bovinos nas imagens, que devem ser cadastradas na ferramenta conforme requisito 2.
5. A ferramenta deve permitir a inclusão, alteração e remoção de feedback para o produtor de possíveis problemas encontrados nas imagens como: tamanho da imagem, excesso de nuvens, entre (Trabalhos futuros).
6. A ferramenta deve permitir cálculo do GSD com base na altura e definição do sensor do VANT (Trabalhos futuros).
7. A ferramenta deve permitir a alteração do resultado de contagem permitindo que o produtor informe, selecionando nas imagens os animais que não foram contados, para ajudar no aprendizado da CNN (Trabalhos futuros).

B2 – Relatório e Consultas

8. A ferramenta deve permitir a consulta da lista de processamentos existentes, permitindo o usuário escolher os que já foram processados, disponibilizando as imagens enviadas e as imagens processadas.

9. A ferramenta deve permitir a consulta das propriedades cadastradas pelo usuário, disponibilizando a liberação de usuários por propriedades.
10. A ferramenta deve permitir a disponibilização de relatórios de imagens processadas por propriedade, categoria animal, tipo de manejo, periódico de envio, período da data do envio.

C – REQUISITOS NÃO FUNCIONAIS

C1. Confiabilidade

11. A ferramenta deve ter capacidade para recuperar os dados perdidos da última operação que realizou em caso de falha.
12. A ferramenta deve permitir o controle de acesso por meio de login e senha. Deve permitir o relacionamento de cada usuário com uma propriedade na ferramenta, por meio de seleção da propriedade no momento de logar. No caso do primeiro login do usuário, quando não existir propriedade registrada na ferramenta, deve permitir o cadastro de pelo menos uma propriedade antes de confirmar o acesso.

C2. Eficiência

13. A ferramenta deve responder a consultas on-line em menos de 5 segundos.

C3. Portabilidade

14. A ferramenta deve ser capaz de armazenar os dados em base de dados MySQL.
15. A ferramenta deve verificar a qualidade da imagem antes de fazer o processamento de contagem (Trabalhos futuros).
16. A ferramenta deve possibilitar a contagem de animais da raça Nelore de fazendas com grande extensão através de imagem adquiridas via satélite (Trabalhos futuros).
17. A ferramenta deve possibilitar a subdivisão das imagens em quadrantes de interesses e contagem de animais da raça Nelore por quadrante (Trabalhos futuros).

B. MANUAL DA SYSCONBOV

Este apêndice apresenta exemplo de uso de todas as telas da ferramenta SYSCONBOV desenvolvida no âmbito deste trabalho, para facilitar a sua utilização.

A primeira tela disponibilizada pela ferramenta é a tela “Login”, onde todos os usuários efetuam o acesso a ferramenta por meio de login e senha únicos. Para isso, o usuário pode se cadastrar clicando no botão “Criar Conta” disponível na mesma tela, conforme exibido nas Figuras 1 e 2.



Figura 1 – Tela de Login

Criar Conta

Dados do Pessoal

Tipo Pessoa: ☒ Física ☐ Jurídica

Selecione o tipo do Usuário...

Nome
Entre com o Nome...

RG
Entre com o Número do RG...

Selecione o Estado...

Entre com o Órgão Expedidor Ex: SSP.

CPF
Entre com o Número do CPF...

Endereço
Entre com o Endereço...

Número
Entre com o Número...

Complemento
Entre com o Complemento...

Bairro
Entre com o Bairro...

Estado

Figura 2 – Tela de criação de usuário para acesso ao SYSCONBOV.

Após o login abrirá a tela inicial da ferramenta, onde está disponível o “Painel Principal” mostrando o total de imagens já cadastradas pelo usuário da ferramenta, a quantidade de imagens já processadas e a quantidade de imagens à processar (imagens que já ocorreu a contagem de bovinos), conforme mostrado na Figure 3. No lado esquerdo desta e de todas as outras páginas existentes na ferramenta está o Menu de acesso, com todas as opções liberadas pelo grupo de usuário.

SYSCONBOV

Painel Principal

Total de Imagens: 6
Ver Detalhes

Imagens Processadas: 5
Ver Detalhes

Imagens para Processar: 1
Ver Detalhes

Menu de Acesso:

- Painel Principal
- Propriedades
- Imagens
- Meus Dados
- Avaliação do Sistema

Usuário: Fabricio Weber

Ações: Usuário, Admin, Logout

Figura 3 – Tela Principal.

Para dar continuidade ao uso da ferramenta, o usuário deverá cadastrar uma nova Propriedade conforme Figura 4 ou pedir acesso a uma Propriedade já cadastrada na ferramenta para um usuário que já efetuou o cadastro da mesma. Na opção “Listar”, do Menu “Propriedade”, o usuário pode ver a lista de Propriedades cadastradas por ele, podendo editar, excluir ou liberar acesso, conforme Figura 5. Posteriormente poderá acessar a tela “Cadastro de Imagens para Contagem”, conforme Figura 6.

SYSCONBOY Fabrício Weber

Cadastro de Propriedade

Dados da Propriedade

Nome *
FAZ. NOSSA SENHORA APARECIDA

CNPJ
47.471.285/0001-64

Inscrição Estadual *
1234567-8

Estado *
MS

Município *
CAMPO GRANDE

E-mail
teste@cadastro.com

Área Total *
10000

Área de Pastagem *
10000

Sobre
teste 1

Campo(s) com * preenchimento obrigatório(s)

Alterar

Figura 4 – Tela de Cadastro de Propriedades.




Figura 5 – Tela de Lista de Propriedades.

Na tela “Cadastro de Imagem para Contagem” selecione a propriedade, o pasto ou invernada, tipo de manejo e categorial animal dos bovinos, a altura do voo do VANT, o tipo do VANT e a data que a imagem foi tirada, por último selecione uma ou mais imagens. O processamento de cálculo das imagens ocorrerá de forma automática durante o envio das imagens.


Fabrizio Weber

Painel Principal
Propriedades
Imagens
Inserir
Listar
Meus Dados
Relatórios
Avaliação do Sistema

Cadastro de Imagem para Contagem

Dados para o Processamento

Propriedade *
Selecione o Propriedade...

Pastagem / Invernada *

Tipo do Manejo
☐ Vermifugação
☐ Vacinação
☐ Rodeio
☐ Salga
☐ Observação de Cio
☐ Mudança de Invernada
☒ Contagem
☐ Outros

Categoria Animal
☐ Novilha 1 ano
☐ Novilha 2 anos
☐ Garrote 1 ano
☐ Garrote 2 anos
☐ Vaca Parida
☐ Vaca Solteira
☐ Vaca com Cria
☐ Touro
☐ Diversos

Altura do voo em Metros *

Tipo do Drone *
Selecione o Drone...

Data das Imagens

Inserir Imagens
Escolher arquivos Nenhum arquivo selecionado

Campo(s) com * preenchimento obrigatório(s)

Figura 6 – Tela de Cadastro de Imagens para Contagem Automática.

Ao término do processamento das imagens serão carregadas na mesma tela a imagem original e a imagem processada contendo os bovinos localizados durante a contagem, conforme Figura 7.




Figura 7 – Tela de imagens original e processada no Cadastro de Imagens.

Para visualizar as imagens processadas, basta acessar o menu “Imagem” opção “Listar”. Será carregada a lista de imagens cadastradas, com a opção de ver todas as imagens cadastradas pelo usuário, bem como visualizar cada imagem original e processada pela ferramenta, conforme Figuras 8 e 9.


Fabrizio Weber

- Painel Principal
- Propriedades
- Imagens**
- Meus Dados
- Relatórios
- Avaliação do Sistema

Lista de Imagens Cadastradas Processadas

Lista de Imagens por Propriedade

Ação	Imagem Nº	Propriedade	Pasto	Dt. Inserção	Situação	Contagem	Validação
 	12	FAZ. NOSSA SENHORA APARECIDA	teste	02/10/2019	Processado	5	5
 	15	FAZ. NOSSA SENHORA APARECIDA	teste	02/10/2019	Processado	7	21
 	18	FAZ. NOSSA SENHORA APARECIDA	teste	25/09/2019	Processado	5	5
 	31	FAZ. NOSSA SENHORA APARECIDA	pasto 100	13/03/2020	Processado	7	7
 	30	FAZ. NOSSA SENHORA APARECIDA	pasto 100	13/03/2020	Processado	7	8
 	35	FAZ. NOVA ALVORADA	pasto 23	26/03/2020	Processado	6	6
 	36	FAZ. NOSSA SENHORA APARECIDA	teste	26/03/2020	Processado	6	6
 	37	FAZ. NOSSA SENHORA APARECIDA	formação	26/03/2020	Processado	5	5
 	38	TESTE 233	borda 2	27/03/2020	Processado	7	7
 	43	TESTE 233	cruzada	23/04/2020	Processado	18	20
 	57	FAZ. NOSSA SENHORA APARECIDA	teste	07/07/2020	Processado	11	0
 	58	FAZ. NOSSA SENHORA APARECIDA	teste	07/07/2020	Processado	11	0
 	80	FAZ. BOA ESPERANÇA	teste	07/07/2020	Processado	5	5
 	67	FAZ. NOSSA SENHORA APARECIDA	teste	07/07/2020	Processado	11	40
 	81	FAZ. BOA ESPERANÇA	teste	07/07/2020	Processado	18	26

 Imagem Enviada
 Imagem Processada
 Contar

Figura 8 – Tela de Lista de Imagens Cadastradas e Processadas.




Figura 9 – Tela de Lista de Imagens Cadastradas com a visualização do processamento.

Na visualização da imagem processada, está disponível um campo para validação da contagem de bovinos onde o usuário informa o número correto de bovinos presente na imagem.

Para acesso a área administrativa, o usuário deverá acessar a opção “Admin” por meio do menu no canto direito superior sobre o nome do usuário, conforme Figura 10.




Figura 10 – Tela de Principal com exibição da opção do menu para acesso a área Administrativa.

Na área administrativa, na página Principal, pode-se observar a quantidade de imagens total lançada na ferramenta, o total de imagens processadas, o total de imagens para processar de todas as propriedades lançadas na área do usuário, e um gráfico do total de propriedades por estado, conforme Figura 11.




Figura 11 – Tela da área administrativa.

As opções existentes no menu da área administrativa são o “Painel Principal”; na opção “Cadastros” com os subitens “Usuário”, “Propriedade” e “Tipo de Drones”; na opção “Relatórios” com os subitens “Imagens Lançadas” e “Propriedades por UF”, conforme Figura 12.




Figura 12 – Tela com as opções de menu da área administrativa.

Na opção “Imagens Lançadas” do menu “Relatórios” é disponibilizada a tela “Relatório de Imagens”. Nessa tela estão disponíveis como opções de filtros o período de envio das imagens (com data início e data fim) e a seleção por propriedade, conforme Figura 13. O relatório emitido disponibilizará uma listagem por propriedade por ordem alfabética, seguida pelos dados do lançamento como: pasto/invernada; manejo; categoria animal, data de envio e quantidade de imagens cadastradas, listando em sequência o Id da imagem com o número de animais contados e o número de animais validados pelos usuários do sistema, conforme Figura 14.

Figura 13 – Tela de Relatório de Imagens

Pasto/Invernada	Manejo	Categoria Animal	Data do Envio	Qtd. Imagem
teste	Contagem		2020-03-12	2

Id Imagem	N° de Animais Contados	N° de Animais Validados
81	18	26
80	5	5

Figura 14 – Tela de Relatório de Imagem por Propriedade

Na opção “Propriedade por UF” do menu “Relatórios” é disponibilizado o relatório das propriedades cadastradas na ferramenta por ordem alfabética por estado, conforme Figura 15.

SYSCONBOV Admin

Fabricio Weber

Painel Principal

Cadastros

Relatórios

Imagens Lançadas

Propriedades por UF

Relatório de Propriedades por Estado

Nome da Propriedade

BA

Id	Nome	Cidade	Gestor
2	FAZ. BOA ESPERANÇA	ANDORINHA	FABRICIO WEBER
38	FAZENDA 3/4	ADUSTINA	FABRICIO WEBER

MA

Id	Nome	Cidade	Gestor
4	FAZENDA SANTO ANTONIO	ANAJATUBA	VANESSA APARECIDA DE MORAES WEBER

MS

Id	Nome	Cidade	Gestor
1	FAZ. NOSSA SENHORA APARECIDA	CAMPO GRANDE	FABRICIO WEBER
3	FAZ. NOVA ALVORADA	ALCINOPOLIS	FABRICIO WEBER
5	FAZ. UBERABA	ANTONIO JOAO	JOÃO FELIPE
6	PONTAL DAS ARARAS	CAMPO GRANDE	MARIA ISTELA CAGNIN
7	PONTAL DAS ARARAS	CAMPO GRANDE	MARIA ISTELA CAGNIN
39	FAZENDA NOSSA SENHORA APARECIDA	CAMPO GRANDE	MARIA ISTELA CAGNIN

Figura 15 – Tela de Relatório de Propriedades por Estado.