

UNIVERSIDADE FEDERAL DO PAMPA

FIAMA JIMENEZ OCHÔA

**TICKCOUNT: UMA ABORDAGEM
PARA CONTAGEM AUTOMÁTICA DE
CARRAPATOS EM BOVINOS**

**Bagé
2026**

FIAMA JIMENEZ OCHÔA

**TICKCOUNT: UMA ABORDAGEM
PARA CONTAGEM AUTOMÁTICA DE
CARRAPATOS EM BOVINOS**

Dissertação apresentada ao Programa de
Pós-Graduação em Computação Aplicada
como requisito parcial para a obtenção do tlo de
Mestre em Computação Aplicada.

Orientador: Sandro da Silva Camargo
Coorientador: Fernando Flores Cardoso

**Bagé
2026**

Ficha catalográfica elaborada automaticamente com os dados fornecidos
pelo(a) autor(a) através do Módulo de Biblioteca do
Sistema GURI (Gestão Unificada de Recursos Institucionais) .

0439t Ochoa, Fiama Jimenez

TickCount: Uma abordagem para contagem automática de
carrapatos em bovinos / Fiama Jimenez Ochoa.
74 p.

Dissertação(Mestrado)-- Universidade Federal do Pampa,
MESTRADO EM COMPUTAÇÃO APLICADA, 2024.
"Orientação: Sandro Da Silva Camargo".

1. TickCount: Uma abordagem para contagem automática de
carrapatos em bovinos . I. Título.

FIAMA JIMENEZ OCHOA

TickCount: Uma abordagem para contagem automática de carrapatos em bovinos

Dissertação apresentada ao Programa de Pós-Graduação em Computação Aplicada da Universidade Federal do Pampa, como requisito parcial para obtenção do Título de Mestre em Computação Aplicada.

Dissertação defendida e aprovada em: 08 de março de 2024.

Banca examinadora:

Prof. Dr. Sandro da Silva Camargo

Orientador
(Unipampa)

Prof. Dr. Jayme Garcia Arnal Barbedo
(Embrapa)

Prof.^a Dr.^a Emanuelle Baldo Gaspar
(Embrapa)

Prof. Dr. Leonardo Bidese de Pinho
(Unipampa)



Assinado eletronicamente por **SANDRO DA SILVA CAMARGO, PROFESSOR DO MAGISTERIO SUPERIOR**, em 06/06/2024, às 09:51, conforme horário oficial de Brasília, de acordo com as normativas legais aplicáveis.



Assinado eletronicamente por **Jayme Garcia Arnal Barbedo, Usuário Externo**, em 07/06/2024, às 19:28, conforme horário oficial de Brasília, de acordo com as normativas legais aplicáveis.



Assinado eletronicamente por **Emanuelle Baldo Gaspar, Usuário Externo**, em 30/07/2024, às 15:38, conforme horário oficial de Brasília, de acordo com as normativas legais aplicáveis.



Assinado eletronicamente por **LEONARDO BIDESE DE PINHO, PROFESSOR DO MAGISTERIO SUPERIOR**, em 13/01/2025, às 10:38, conforme horário oficial de Brasília, de acordo com as normativas legais aplicáveis.



A autenticidade deste documento pode ser conferida no site https://sei.unipampa.edu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **1382831** e o código CRC **BB7187EE**.

Dedico este trabalho a Deus, meus pais,
irmão, marido e filha.

AGRADECIMENTO

Agradeço à maravilhosa UNIPAMPA por ter me aberto suas portas, agradeço à República Federativa do Brasil por não me negar a oportunidade de receber educação gratuita de qualidade como estrangeira. Agradeço aos professores Sandro da Silva Camargo, Ana Paula Ludtke Ferreira, Naylor Bastiani Perez e Leonardo Bidese de Pinho pelo maravilhoso trabalho como professores e promotores da criação de conhecimento. Agradeço à Embrapa e aos técnicos da Embrapa Bernardo Macke Franck e Rossana Leitzke Granada pela ajuda na coleta de dados para o desenvolvimento deste trabalho.

"Todo aquel que lucha, es digno de la gloria."

— Manuel Salvador Ochoa Arrieta

RESUMO

As proteínas são nutrientes essenciais na alimentação humana. Assim, a pecuária contribui não só para a estabilidade alimentar e nutrição, mas também para a redução da pobreza e crescimento econômico nas regiões produtoras. Para alimentar a crescente população mundial, de forma alinhada com preocupações ambientais, é fundamental o desenvolvimento de uma pecuária eficiente e sustentável, atenta com o bem estar animal. Dentre os principais fatores que causam problemas de saúde e consequentes perdas econômicas na bovinocultura, estão os carrapatos, tanto como parasitas hematófagos quanto como vetores de patógenos e toxinas. A identificação e contagem de carrapatos em bovinos é essencial para o manejo precoce da infestação, além de ser uma característica econômica importante utilizada no melhoramento genético. No entanto, a contagem manual de carrapatos em bovinos é tediosa, trabalhosa e demorada. Neste contexto, este trabalho visa tratar o seguinte problema de pesquisa: *É possível quantificar automaticamente carrapatos em bovinos por meio de um modelo computacional?*. Além disso, o objetivo principal deste trabalho é desenvolver uma abordagem autônoma, baseada em inteligência artificial, para detectar e quantificar os carrapatos em bovinos através de imagens. Em termos metodológicos, este trabalho é uma pesquisa aplicada, que envolve a coleta de imagens em ambientes reais de manejo, anotação de carrapatos nas imagens coletadas, criação de uma base de imagens de treinamento, construção de modelos de aprendizado profundo para contagem de carrapatos e avaliação dos modelos criados. Os resultados mostram que o modelo apresentado neste trabalho foi capaz de detectar carrapatos com 0,91 de acurácia.

Palavras-chave: Aprendizado profundo; Pecuária de precisão; Inteligência artificial; Parasitas; Sanidade animal.

ABSTRACT

Proteins are essential nutrients in human nutrition. Thus, livestock farming contributes not only to food stability and nutrition, but also to poverty reduction and economic growth in producing regions. To feed the growing world population, in line with environmental concerns, it is essential to develop efficient and sustainable livestock farming, attentive to animal welfare. Among the main factors that cause health problems and consequent economic losses in cattle farming are ticks, both as blood-sucking parasites and as vectors of pathogens and toxins. The identification and counting of ticks in cattle is essential for early management of the infestation, in addition to being an important economic characteristic used in genetic improvement. However, manually counting ticks on cattle is tedious, laborious and time-consuming. In this context, this work aims to address the following research problem: *Is it possible to automatically quantify ticks in cattle through a computational model?*. Furthermore, the main objective of this work is to develop an autonomous approach, based on artificial intelligence, to detect and quantify ticks in cattle through images. In methodological terms, this work is applied research, which involves collecting images in real management environments, annotating ticks in the collected images, creating a training image base, building deep learning models for counting ticks and evaluation of the created models. The results show that the model presented in this work was able to detect ticks with 0.91 accuracy.

Keywords: Deep Learning; Precision Livestock; Artificial intelligence; Parasites; Animal health.

LISTA DE FIGURAS

Figura 1	Imagem da parte traseira de um bovino infestado com carrapatos.....	21
Figura 2	Processo de desenvolvimento do modelo.	22
Figura 3	Ciclo de vida de <i>R. microplus</i>	23
Figura 4	Segmentação baseado em regiões.....	27
Figura 5	Segmentação baseado em regiões.....	28
Figura 6	Divisão e fusão de regiões.	28
Figura 7	Interação teórica entre saúde animal (em azul), IA e seus principais subcampos (em vermelho) e outros campos de pesquisa relacionados (em preto)....	29
Figura 8	Tipos de aprendizado de máquina.	30
Figura 9	Exemplo de aprendizado supervisionado.	30
Figura 10	(a) Exemplo $(x, f(x))$ pares e uma hipótese linear consistente. (b) Uma hipótese polinomial consistente de grau 7 para o mesmo conjunto de dados. (c) Um conjunto de dados diferente, que admite um ajuste polinomial de grau 6 exato ou um ajuste linear aproximado. (d) Um ajuste senoidal simples e exato para o mesmo conjunto de dados.	31
Figura 11	Exemplo de aprendizado não supervisionado.....	31
Figura 12	A) Camada greedy de aprendizado. B) Modelo híbrido de Rede de Crenças Profundas ou <i>Deep Belief Network (DBN)</i> após aprendizado greedy. As duas camadas superiores formam a máquina de Boltzmann restrita (RBM) e as inferiores uma rede direta de crença.	32
Figura 13	Algoritmo de aprendizado por reforço.	33
Figura 14	Estrutura simplificada de uma rede neural convolucional.	34
Figura 15	Exemplo de operação de convolução.....	35
Figura 16	Um exemplo de operação de agrupamento.....	35
Figura 17	Um exemplo de como funciona a camada <i>Dropout</i>	36
Figura 18	Área sob a curva (AUC).	40
Figura 19	Função $y=x$	41
Figura 20	Revisão sistemática da literatura.	43
Figura 21	Quantidade de trabalhos selecionados e aceitos em cada base de dados.....	44
Figura 22	Saída <i>YOLO</i> final que consiste em coordenadas de caixa, pontuações de objetividade e pontuações de classe.....	54
Figura 23	Arquivo .TXT com as coordenadas de cada carrapato na imagem anotada. ..	54

Figura 24	Anotação de carrapatos com labelImg.....	55
Figura 25	Distribuição da quantidade de carrapatos por imagem.....	55
Figura 26	Distribuição das dimensões das caixas delimitadoras das anotações.	56
Figura 27	Estrutura da rede <i>YOLO</i>	57
Figura 28	Estrutura da rede <i>YOLOv5</i>	57
Figura 29	Resultados de avaliação das métricas.	59
Figura 30	Matriz de confusão.	60
Figura 31	Imagens de validação.....	61
Figura 32	Teste de modelo em um cachorro.	61
Figura 33	Teste de modelo em um bovino de outra raça.	62

LISTA DE TABELAS

Tabela 1	Matriz de confusão binária.	38
Tabela 2	Arquivos aceitos na revisão sistemática.	52
Tabela 3	Estatística descritiva da quantidade de carrapatos por imagem.....	54
Tabela 4	Estatística descritiva das dimensões das caixas delimitadoras das anotações..	55

LISTA DE ABREVIATURAS E SIGLAS

CNN	Rede neural convolucional (<i>Convolutional neural network</i> em inglês)
DBN	Rede de Crenças Profundas (<i>Deep Belief Network</i> em inglês)
DCNN	Rede neural densamente conectada (<i>Densely connected neural network</i> em inglês)
DCRN	Rede convolucional recorrente densamente conectada (<i>Densely connected recurrent convolutional network</i> em inglês)
DL	Aprendizado profundo (<i>Deep Learning</i> em inglês)
DNN	Rede neural profunda (<i>Deep neural network</i> em inglês)
IA	Inteligência Artificial (<i>Artificial Intelligence</i> em inglês)
IoU	Coeficiente de similaridade de Jaccard (<i>Jaccard similarity coefficient</i> em inglês)
MAE	Erro médio absoluto (<i>Mean Absolute Error</i> em inglês)
mAp	Precisão média média (<i>Mean Average Precision</i> em inglês)
MSE	Erro quadrático médio (<i>Mean Square Error</i> em inglês)
R-CNN	Rede Neural Convolucional Regional mais rápida (<i>Fastest Regional Convolutional Neural Network</i> em inglês)
RGB	Vermelho-Verde-Azul (<i>Red-Green-Blue</i> em inglês)
RNN	Rede neural recorrente (<i>Recurrent neural network</i> em inglês)
R ₂ U-Net	Rede neural convolucional residual recorrente baseado em U-Net (<i>Recurrent residual convolutional neural network based on U-Net</i> em inglês)
UAV	Veículos Aéreos não tripulados (<i>Unmanned Aerial Vehicles</i> em inglês)
UD-Net	Modelo de regressão baseado em R2UNet chamado University of Dayton Net (<i>Regression model based on R2UNet named University of Dayton Net</i> em inglês)
YOLO	Abordagem Você só olha uma vez (<i>Abordagem You Only Look Once</i> em inglês)

SUMÁRIO

1 INTRODUÇÃO	15
1.1 Problema de Pesquisa	16
1.2 Objetivos	16
1.3 Organização do Trabalho	16
2 METODOLOGIA	18
2.1 Caracterização da Pesquisa	18
2.2 Delimitação do Problema	18
2.3 Revisão Sistemática de Literatura.....	19
2.4 Delineamento Experimental.....	20
2.5 Coleta de Imagens	20
2.6 Ambiente de Desenvolvimento	20
2.7 Riscos e Dificuldades.....	21
2.8 Resultados Esperados	21
2.9 Processo de desenvolvimento	22
3 REVISÃO BIBLIOGRÁFICA.....	23
3.1 Ciclo de vida de <i>Rhipicephalus microplus</i>	23
3.2 Tratamento e diagnóstico	24
3.3 Diagnóstico Precoce	25
3.4 Aspectos Tecnológicos.....	25
3.4.1 Visão Computacional.....	26
3.4.2 Segmentação de imagem.....	26
3.4.2.1 Técnicas de segmentação de imagem	26
3.5 Inteligência Artificial	28
3.5.1 Aprendizado de máquina	29
3.5.2 Aprendizado Profundo (DL)	34
3.6 Métricas de avaliação de modelos.....	36
3.7 Ferramentas.....	40
3.7.1 Python	40
3.7.2 <i>Tensorflow</i>	41
3.7.3 Keras	42
3.8 Trabalhos Correlatos	42

4 ABORDAGEM PROPOSTA.....	53
4.1 Anotação	53
4.2 Arquitetura	56
4.3 Treinamento e teste	58
4.4 Resultados e Discussão	58
4.4.1 Utilização do Modelo	59
5 CONCLUSÕES	63
5.1 Trabalhos Futuros.....	64
REFERÊNCIAS.....	65

1 INTRODUÇÃO

No Brasil, a pecuária teve início no século XV, na atual cidade de São Paulo (antiga capitania de São Vicente) e se espalhou por todo o litoral. Com o passar do tempo, essa atividade deslocou-se para o interior do país devido à pressão exercida pelo cultivo da cana-de-açúcar, instalando-se, nesta fase inicial, no eixo Sul-Sudeste, abrangendo São Paulo, Minas Gerais e a Região Sul (TEIXEIRA; HESPANHOL, 2014). Ao longo do tempo, a pecuária tornou-se uma das atividades mais importantes para a economia brasileira. Além disso, a economia pecuária consolidou-se como a principal atividade econômica do território gaúcho durante o século XIX (FARINATTI, 2017).

Atualmente, a demanda e a produção de proteína bovina estão em expansão devido ao crescimento populacional, mudanças no estilo de vida e aumento da renda. Como pressões ambientais dificultam a ampliação da área para produção, tem se buscado o aumento da densidade animal evitando o aumento de área, o que pode favorecer a infestação parasitária. Assim, a rentabilidade da atividade pecuária pode ser significativamente reduzida pelos efeitos de parasitas que afetam o rebanho (GRISI, 2014).

Neste contexto, os carrapatos causam perdas econômicas significativas tanto como parasitas hematófagos quanto vetores de patógenos e toxinas (GRISI, 2014). Visando buscar a eficiência dos métodos de controle, a infestação deve ser identificada e quantificada na sua fase inicial. O método mais comum baseia-se na contagem de fêmeas ingurgitadas entre 4 e 8 mm de comprimento, palpando um lado do animal e depois extrapolando para todo o corpo, multiplicando por dois (WHARTON; UTECH, 2007; CORTIVO et al., 2016). Este método, embora bem estabelecido, tem algumas deficiências: o processo é lento e tedioso, está sujeito a fenômenos psicofísicos e ópticos (BARBEDO, 2016) e os animais devem estar contidos para realização da avaliação (CORTIVO et al., 2016).

Para facilitar diversas atividades humanas, novas tecnologias têm sido utilizadas. Na pecuária, não é diferente, havendo uma série de problemas onde podem ser aplicadas tecnologias, principalmente a Inteligência Artificial (IA). IA abrange uma ampla gama de teorias e tecnologias usadas para resolver problemas de alta complexidade lógica ou algorítmica. A IA apresenta três desafios que também fazem sentido na saúde animal: (i) entender a situação e sua dinâmica como, por exemplo, a disseminação de carrapatos; (ii) a percepção do ambiente, que corresponde à interação entre a saúde animal e a detecção de

padrões (como a contagem de carrapatos), formas (como identificar os tipos de carrapato) e sinais (como o aumento da incidência de carrapatos) em diferentes escalas; (iii) tomada de decisão por máquina e suporte à decisão humana, como auxílio no diagnóstico de doenças (EZANNO et al., 2021). Assim, a IA tem se consolidado como parte essencial da evolução tecnológica do agronegócio. As aplicações mais relevantes da IA na agricultura são robótica, monitoramento de culturas e solo, e análise preditiva (AGRONET, 2019). Por exemplo, os engenheiros procuram criar robôs e sensores para medir novas variáveis biológicas e ambientais na produção agrícola, como prever o fenótipo do genótipo (TUGGLE et al., 2022).

1.1 Problema de Pesquisa

Neste contexto, este trabalho aborda o seguinte problema de pesquisa: *É possível quantificar automaticamente carrapatos em bovinos por meio de um modelo computacional?*

1.2 Objetivos

Este trabalho tem como objetivo geral desenvolver uma abordagem autônoma, baseada em inteligência artificial, para detectar e quantificar os carrapatos em bovinos através de imagens.

Os objetivos específicos são:

- Coletar uma base de imagens, em ambiente real de manejo, com animais infectados por carrapatos;
- Desenvolver uma abordagem para identificação dos carrapatos nas imagens;
- Construir e avaliar modelos para contagem de carrapatos;
- Testar a capacidade de generalização do modelo mais acurado;

1.3 Organização do Trabalho

O restante deste trabalho está organizado da seguinte forma: O capítulo 2 apresenta a forma como a pesquisa foi realizada, descrevendo a caracterização e

delimitação do problema, o processo de revisão sistemática da literatura, a coleta e análise de dados, riscos e dificuldades possíveis durante a investigação, os resultados esperados e, finalmente, o processo de desenvolvimento. O capítulo 3 mostra os conceitos importantes para compreensão deste trabalho e os trabalhos relacionados que foram encontrados durante a revisão sistemática da literatura. O capítulo 4 discute a abordagem proposta e os resultados preliminares. O capítulo 5 resume as considerações finais.

2 METODOLOGIA

Este capítulo apresenta os passos envolvidos na realização desta pesquisa, descrevendo a caracterização e delimitação do problema, o processo de revisão sistemática da literatura, a coleta e análise dos dados, riscos e dificuldades apresentados durante a investigação, os resultados esperados e, finalmente, o processo de desenvolvimento da solução de software.

2.1 Caracterização da Pesquisa

Quanto à sua natureza, este projeto consiste em uma pesquisa aplicada, pois visa solucionar um problema real no contexto da pecuária ¹. Quanto à sua abordagem, trata-se de uma pesquisa quantitativa, pois serão utilizados dados numéricos para validar a hipótese de pesquisa, que neste caso é quantificar automaticamente a infestação de carrapatos por meio de uma abordagem computacional autônoma. O procedimento desta investigação é principalmente experimental, pois coleta dados através da experimentação, permitindo analisar diferentes contextos e também, verificar como os fatores manipulados na investigação impactaram o resultado gerado ². Também são realizados procedimentos bibliográficos, para encontrar outros projetos com a mesma finalidade deste, através de uma revisão sistemática da literatura. Além disso, são aplicados procedimentos de estudos de campo, uma vez que os dados para esta pesquisa foram coletados de um ambiente real, diretamente a campo, em atividades de manejo nas instalações da EMBRAPA Pecuária Sul.

2.2 Delimitação do Problema

A delimitação do problema foi feita juntamente com a equipe da EMBRAPA Pecuária Sul, onde foram realizadas entrevistas com servidores da área de sanidade animal que apresentaram a problemática envolvida nas infestações de carrapatos e as consequências em termos de perdas econômicas para os produtores. Foram apresentadas pelo orientador da Unipampa e pela mestrandia as possibilidades de uso de tecnologias e escolhida, em conjunto, a abordagem mais viável.

¹<https://economipedia.com/definiciones/investigacion-aplicada.html>

²<https://economipedia.com/definiciones/investigacion-experimental.html>

2.3 Revisão Sistemática de Literatura

A revisão sistemática da literatura foi realizada utilizando a ferramenta *Parsifal*³. Foram utilizados os seguintes termos de busca: *automatic count*, *image segmentation* e *deep learning*. Foram selecionadas as fontes de pesquisa *Springer Link*, *Scopus*, *MDPI*, *IEEE Digital Library* e *ACM Digital Library*. Além disso, critérios de inclusão e exclusão também foram definidos.

Os critérios de inclusão foram os seguintes:

- *Publicações dos últimos quatro anos*: Devido ao rápido avanço da tecnologia e à grande quantidade de artigos publicados a cada ano, houve a necessidade de delimitar um curto período de tempo para esta revisão. Neste contexto, optou-se por escolher os trabalhos publicados nos últimos quatro anos até o momento em que este estudo foi realizado, ou seja, de 2019 a 2022;
- *Publicações que utilizam ferramentas inovadoras*: Ferramentas inovadoras são aquelas capazes de gerar novos resultados que contribuam para a melhoria dos processos e que, além disso, não tenham sido utilizadas ou mencionadas pelo menos da mesma forma em outros trabalhos;
- *Publicações que utilizam técnicas automáticas ou de processamento de imagem*: Foram analisadas publicações que realizam estudos de *deep learning* e/ou com processamento de imagens.

Os critérios de exclusão utilizados foram os seguintes:

- *Não declaram explicitamente linguagens ou ferramentas utilizadas*: Isso corresponde ao principal critério de exclusão, pois por meio desta revisão sistemática da literatura, busca-se encontrar trabalhos que utilizem ferramentas que possam ser aplicadas na detecção e contagem de carrapatos. Portanto, é necessário que eles declarem qual ferramenta foi utilizada;
- *Não realizam análises automatizadas*: Este critério corresponde a trabalhos que não realizam análises automaticamente, ou seja, que dependam de supervisão humana. Esse tipo de análise envolve conjuntos de algoritmos que podem distinguir e contar qualquer objeto encontrado em imagem ou vídeo (WEITZMAN, 2002). Portanto, aqueles trabalhos que não usam algoritmos autônomos para detectar ou quantificar objetos são excluídos.

³<https://parsif.al/>

2.4 Delineamento Experimental

Para a captura das imagens, foram utilizados cem animais da raça Brangus (entre dois e quatro anos) infestados ou não com carrapatos *Rhipicephalus (Boophilus) microplus*, 3 a 8 imagens foram capturadas por animal. As partes do corpo selecionadas para as imagens foram o pescoço e abaixo da cauda. Estas áreas foram escolhidas porque, quando os carrapatos escolhem seu hospedeiro, eles procuram locais com pele solta e alta vascularização (GARCÍA, 2014). As imagens foram capturadas em atividades de manejo realizadas nas instalações da Embrapa Pecuária Sul, Latitude: -31.34777777, Longitude: -54.01333333.

2.5 Coleta de Imagens

O dispositivo de captura de imagens foi um celular Samsung Galaxy J5 Prime, modelo SM-G570M, com câmera de 13 megapixels, 28mm (wide), AF 28mm (F1,9), ISO 100, com tempo de exposição de 1/30 segundos. O banco de imagens coletado é composto 500 imagens de animais infestados nas condições descritas na seção anterior. O dispositivo de captura estava uma distância aproximada de 1 metro dos animais. As fotos foram feitas entre 8h30 e 11h30, no dia 27 de novembro de 2019, com temperaturas ambientais que variaram entre 16,7 e 19,1 °C, umidade relativa do ar entre 77 e 95%, velocidade do vento entre 1,2 e 4,1 m/s e a temperatura da superfície da pele do animal variou entre 27,7 e 32,7°C como em (BARBEDO et al., 2017). A Figura 1 mostra o exemplo de uma das imagens coletadas.

2.6 Ambiente de Desenvolvimento

O pré-processamento é usado principalmente para preparar os dados de mídia, codificação e decodificação completa de imagem e vídeo, conversão de formato e outras operações (Huawei Technologies Co., 2023). Portanto, o pré-processamento é a etapa fundamental para o sucesso da etapa de aplicação dos algoritmos de aprendizado de máquina. Nesta fase, algumas das imagens coletadas foram pré-processadas através da ferramenta *labelimg*, que foi usada para anotar os carrapatos presentes nas imagens selecionadas, esta anotação foi feita manualmente pela autora e o orientador deste

Figura 1 – Imagem da parte traseira de um bovino infestado com carrapatos.



Fonte: Próprio autor (2023).

trabalho. Por meio desta ferramenta, obtém-se um arquivo em texto plano, no formato .TXT, com as coordenadas dos carrapatos identificados em cada imagem.

2.7 Riscos e Dificuldades

Os riscos e dificuldades que se vislumbram para esta pesquisa estão principalmente relacionados à qualidade e quantidade de imagens. As imagens não foram coletadas em um ambiente controlado, mas em um ambiente real de manejo, sem padronização de condições de luminosidade, e com os animais eventualmente em movimento no momento da foto, o que fez com que algumas fotos ficassem tremidas pelo efeito do movimento. A oclusão gerada pela pelagem do animal também é um grande desafio pois, às vezes, não permite detectar a presença de carrapatos que estão total ou parcialmente encobertos. A pelagem preta dos animais também gera mais dificuldade ao processo de identificação dos carrapatos pelo pouco contraste entre os carrapatos e o pêlo do animal.

2.8 Resultados Esperados

O projeto foi planejado e organizado com a meta de desenvolver uma solução computacional para contagem de carrapatos que possa ser usada por meio de um aplicativo computacional e ser usado através de dispositivos móveis. Espera-se que a solução tenha um alto nível de correlação com os resultados da contagem manual

realizada pelo especialista nesta atividade, que pode ser um servidor da Embrapa Pecuária Sul, profissional com formação na área de Ciências Agrárias ou um produtor rural.

2.9 Processo de desenvolvimento

O processo de desenvolvimento de um modelo de aprendizado profundo é realizado da seguinte forma (Figura 2): Neste trabalho, primeiramente foi realizada a coleta de 500 imagens de bovinos nas instalações da EMBRAPA Pecuária Sul. Posteriormente, o pré-processamento de 48 imagens selecionadas aleatoriamente, com posterior anotação dos carrapatos visíveis nas imagens. As imagens foram então divididas aleatoriamente em conjuntos de treinamento e teste. Um modelo de IA foi então treinado para detectar e quantificar os carrapatos nas imagens. Posteriormente, o modelo treinado foi avaliado. Finalmente, o modelo testou sua capacidade de generalização nas imagens do conjunto de testes.

Figura 2 – Processo de desenvolvimento do modelo.



Fonte: Próprio autor (2023).


3 REVISÃO BIBLIOGRÁFICA

Este capítulo apresenta uma breve revisão bibliográfica sobre o ciclo de vida do carrapato *Rhipicephalus microplus*, tratamento, diagnóstico e a importância do diagnóstico precoce. Em seguida, são apresentados os aspectos tecnológicos, as métricas de avaliação, ferramentas e trabalhos relacionados ao objetivo deste trabalho.

3.1 Ciclo de vida de *Rhipicephalus microplus*

A Figura 3 apresenta graficamente o ciclo de vida dos carrapatos *Rhipicephalus microplus*. Este carrapato é parasita de um único hospedeiro (QUIROZ, 1990) até o momento da postura dos ovos. O carrapato cai do animal e deposita os ovos em fendas, pedregulhos, até mesmo sob rochas (SOULSBY, 1987) e eclodem no ambiente. As larvas então se movem pelo solo até encontrar um hospedeiro, como mostrado na Figura 3, etapa 1.

Figura 3 – Ciclo de vida de *R. microplus*.



Fonte: Adaptada de Departamento de Control de Productos Veterinarios (2020).

Carrapatos recém-nascidos (larvas) são geralmente encontrados presos às áreas com pele solta e alta vascularização (GARCÍA, 2014), como a parte interna das coxas, flancos e patas traseiras (Figura 3, etapa 2). As larvas, depois de se alimentarem do hospedeiro, mudam duas vezes: elas se transformam em ninfas e depois em carrapatos adultos (The Center for Food Security & Public Health, 2007) (Figura 3, etapa 3).

Os carrapatos machos adultos tornam-se sexualmente maduros após a alimentação e acasalam com as fêmeas (The Center for Food Security & Public Health, 2007) (Figura 3, etapa 4). Um carrapato fêmea adulto que se alimentou e acasalou, após passar por um ingurgitamento final, se separa de seu hospedeiro e deposita grande número de ovos no ambiente (WHARTON; UTECH, 2007) (Figura 3, etapa 5). Carrapatos do subgênero *Rhipicephalus* (*Boophilus*) *microplus* podem completar seu ciclo de vida em 3 a 4 semanas. O carrapato fêmea morre após a oviposição (The Center for Food Security & Public Health, 2007) (Figura 3, etapa 6).

3.2 Tratamento e diagnóstico

O controle do carrapato tem sido baseado no uso de ixodicidas como organoclorados (OCs), Organofosfatos (OFs), piretróides sintéticos (PSs) e amidinas (Am), entretanto, seu uso irracional gerou populações resistentes de *Rhipicephalus* (*Boophilus*) *microplus*. No México, a resistência de *Rhipicephalus* (*Boophilus*) *microplus* a ixodicidas ocorre principalmente de forma múltipla (multirresistência), sendo um dos principais problemas no programa de controle desse carrapato. O controle não químico baseia-se principalmente no uso de bovinos resistentes, predadores, manejo de pastagens, controle biológico e vacinas. O controle mais promissor é o manejo integrado de pragas baseado na combinação de diversas ferramentas com o intuito de reduzir a dependência de agentes antiparasitários e utilizá-los em momentos/animais que não aumentem a pressão da seleção genética (ROMERO et al., 2011).

As ações de saúde e custos associados são justificáveis no combate às populações de carrapatos multirresistentes e assim evitar a formação de carrapatos resistentes a todos os acaricidas (CUORE et al., 2015). No Uruguai, a evolução no aparecimento da resistência do carrapato a novas moléculas, bem como a presença de populações multirresistentes comprometem a viabilidade técnica do controle efetivo do parasita (CUORE; SOLARI, 2014). No Brasil, foi relatado que existem populações de carrapatos resistentes a todos os princípios ativos disponíveis (KLAFKE et al., 2013). O principal desafio que existe mundialmente é o uso eficiente de um programa integrado de parasitas na pecuária através da implementação de diferentes estratégias de controle químico e não químico (RODRÍGUEZ-VIVAS et al., 2014).

A subdosagem de drogas são os principais fatores que contribuem para o desenvolvimento de populações resistentes (FURLONG; MARTINS, 2000). A resistência

é definida como "a capacidade de uma cepa parasitária sobreviver e/ou multiplicar-se, apesar da administração e absorção de um fármaco administrado em doses iguais ou superiores às usualmente recomendadas, mas dentro dos limites de tolerância do indivíduo"(PROKOPEV, 1965). Conseqüentemente, ocorre a propagação de alelos que conferem resistência às próximas gerações de parasitas. Portanto, relatos de populações de *Rhipicephalus (Boophilus) microplus* resistentes a acaricidas no Brasil e relatos de cepas multirresistentes têm se tornado mais frequentes (HIGA et al., 2015); por isso é necessário que cada produtor faça um diagnóstico correto para que seja eficaz no tratamento e controle da presença desse parasita.

3.3 Diagnóstico Precoce

Nos últimos dois séculos, o conhecimento aumentou muito rapidamente com a descoberta dos parasitas causadores da babesia bovina, os agentes pelos quais são transmitidos e novos meios de diagnóstico, tratamento e prevenção (PIPANO; HADANI, 1984). A falta de ferramentas de vigilância suficientes para a detecção de carrapatos da febre bovina é uma necessidade urgente para manter um programa de erradicação bem-sucedido, esta situação é de fato uma emergência que requer intervenções imediatas (LEÓN et al., 2010). Também, a vigilância é fundamental para determinar se as mudanças nos fatores ambientais estão afetando as populações de carrapatos e/ou a dinâmica de transmissão de patógenos (PEÑA et al., 2009). Essas doenças podem ser prevenidas reduzindo a transmissão vetorial, o controle intensivo do carrapato *Boophilus microplus* reduz drasticamente a transmissão de ambas as Babesias (CIPOLINI; MANGOLD; JACOBO, 2004). Portanto, este trabalho foi realizado em busca de beneficiar o diagnóstico precoce de carrapatos impedindo sua disseminação e reduz perdas.

este trabalho se realiza en busca de beneficiar

3.4 Aspectos Tecnológicos

Este capítulo apresenta uma breve descrição dos aspectos tecnológicos comumente utilizados para detectar objetos em imagens através da segmentação de imagens.

3.4.1 Visão Computacional

A visão computacional é um dos ramos da inteligência artificial e do aprendizado de máquina que pode ser considerada como o estudo da percepção visual de um ponto de vista abstrato (MARROQUIN, 1993). Assim, a visão computacional busca replicar computacionalmente as capacidades da visão humana, como observar e compreender. Os assuntos que a visão computacional trata principalmente incluem classificação de imagens, detecção de objetos, segmentação de imagens, rastreamento visual, reconhecimento de texto e reconhecimento facial (Huawei Technologies Co., 2023). Neste trabalho, a segmentação de imagens foi aplicada para detecção de objetos em imagens.

3.4.2 Segmentação de imagem

A segmentação de imagem é o processo de dividir uma imagem em partes ou regiões. Muitas vezes a divisão em partes é baseada nas características dos pixels na imagem. Por exemplo, uma maneira de encontrar regiões em uma imagem é procurar descontinuidades abruptas nos valores de pixel, que geralmente indicam a presença de bordas. Essas bordas podem definir regiões. Em outros métodos, a imagem é dividida em regiões com base nos valores de cor ou textura ¹.

3.4.2.1 Técnicas de segmentação de imagem

Os atributos básicos de segmentação de uma imagem são: luminância em imagens monocromáticas, componentes de cor em imagens coloridas, textura, forma, etc (GONZALEZ, 1996). Os algoritmos de segmentação de imagem monocromática são geralmente baseados em uma das duas propriedades básicas dos valores de nível de cinza: descontinuidade e similaridade (CONCHA, 2009).

- Detecção de arestas: A detecção de linhas, pontos isolados e arestas em uma imagem são as questões mais importantes da descontinuidade. Na descontinuidade, o método consiste em dividir uma imagem com base em mudanças bruscas no nível de cinza. Os métodos de extração de arestas de uma imagem baseiam-se na diferença que uma característica experimenta em duas regiões adjacentes e que


¹<https://es.mathworks.com/help/images/image-segmentation.html>

indica a existência de uma aresta. Uma das técnicas mais comuns para detectar arestas bidimensionais (2D) é o uso de derivadas de primeira ordem usando o operador gradiente (CONCHA, 2009). O gradiente de uma imagem é uma função $f(x,y)$ definida como um vetor bidimensional conforme apresentado na equação (1).

$$G(F(x, y)) = \begin{bmatrix} G_x \\ G_y \end{bmatrix} = \begin{bmatrix} dF / dx \\ dF / dy \end{bmatrix} \quad (1)$$

- Baseado em regiões: Para segmentar uma imagem por regiões, são utilizadas propriedades espaciais, ou seja, a imagem é dividida em regiões conectadas, onde cada região possui propriedades diferentes que as diferenciam umas das outras. Ou seja, esta abordagem tenta extrair objetos de uma imagem, que podem ser processados de forma independente (CONCHA, 2009).

Figura 4 – Segmentação baseado em regiões.



Fonte: Concha (2009).

Por exemplo, na Figura 4, pode-se observar que uma imagem foi subdividida em duas regiões, em cada região é identificado um conjunto de objetos ou subimagens. As técnicas mais utilizadas são:

- Crescimento de regiões: Consiste no crescimento de regiões agrupando pixels adjacentes que possuem características ou propriedades semelhantes. Como apresentado na Figura 5, partindo de um conjunto de pontos iniciais denominados semente e crescendo as regiões, somando aos pontos sementes os pontos vizinhos que possuem propriedades semelhantes, como intensidade, textura e cor.
- Divisão e fusão de regiões: Consiste em dividir inicialmente uma imagem em um conjunto de regiões disjuntas arbitrárias (CONCHA, 2009). Por exemplo, na Figura 6 a imagem foi segmentada em 1405 regiões, as regiões

Figura 5 – Segmentação baseado em regiões.



Fonte: Concha (2009).

adjacentes são mescladas se tiverem propriedades semelhantes, como nível de cinza, ou são divididas se não compartilharem as mesmas propriedades, como consideráveis variações de níveis de cinza. Finalmente, a imagem é segmentada em um conjunto de regiões homogêneas.

Figura 6 – Divisão e fusão de regiões.




Fonte: Concha (2009).

As técnicas não são exclusivas, mas são combinadas de acordo com o tipo de aplicação (CONCHA, 2009).

3.5 Inteligência Artificial

A inteligência artificial é definida como “*a teoria e o desenvolvimento de sistemas de computador capazes de executar tarefas que normalmente requerem inteligência humana, como percepção visual, reconhecimento de fala, tomada de decisão e tradução entre idiomas*” (SANGHANI; DOUKKY, 2018). Tem havido muito debate sobre o uso de inteligência artificial na medicina, particularmente na radiologia e na interpretação de imagens. Na Figura 7, pode ser vista a interação teórica entre saúde animal (em azul), IA e seus principais subcampos (em vermelho) e outros campos de pesquisa relacionados (em preto). As técnicas de IA mais avançadas incluem aprendizado de máquina (ou *Machine*

Figura 7 – Interação teórica entre saúde animal (em azul), IA e seus principais subcampos (em vermelho) e outros campos de pesquisa relacionados (em preto).



Fonte: Adaptada de Ezanno et al. (2021).

Learning) e a mais recente conhecida como Aprendizado Profundo (ou *Deep Learning*).

3.5.1 Aprendizado de máquina

Aprendizado de máquina é um subcampo da inteligência artificial que lida com algoritmos de computação que podem ser melhorados via dados de treinamento sem programação explícita. É considerado o caminho mais promissor para alcançar a inteligência artificial verdadeiramente próxima à humana (HASSAN et al., 2021). O aprendizado de máquina pode ser usado para facilitar muitas atividades, desde carros

autônomos até a modernização da prática da medicina (SANGHANI; DOUKKY, 2018). A Figura 8 mostra os tipos de aprendizado de máquina.


Figura 8 – Tipos de aprendizado de máquina.



Fonte: Silva (2020).

- **Aprendizado supervisionado:** O aprendizado supervisionado consiste em aprender uma função a partir de exemplos de seus dados de entradas e rótulos (NORVIG, 2002). Usa rótulos para tirar conclusões relacionadas à tarefa de aprendizado sobre os dados inseridos (YAN et al., 2018). A Figura 9, mostra um exemplo de aprendizado supervisionado onde as entradas possuem imagens e informações sobre as características das maçãs e assim o modelo retorna uma predição que corresponde com às informações inseridas nas variáveis de entrada. No aprendizado

Figura 9 – Exemplo de aprendizado supervisionado.




Fonte: Adaptada de Yan et al. (2018).

supervisionado, o modelo recebe um conjunto de entradas com suas respectivas saídas e busca encontrar uma função que estabeleça uma relação aproximada entre

elas. Mais formalmente, o modelo baseado no aprendizado supervisionado busca encontrar uma função $h(x_i)$, denominada hipótese, que se aproxime da função $f(x_i)$, onde $f(x_i)$ é a saída da i -ésima entrada de x (NORVIG, 2002). Os exemplos

Figura 10 – (a) Exemplo $(x, f(x))$ pares e uma hipótese linear consistente. (b) Uma hipótese polinomial consistente de grau 7 para o mesmo conjunto de dados. (c) Um conjunto de dados diferente, que admite um ajuste polinomial de grau 6 exato ou um ajuste linear aproximado. (d) Um ajuste senoidal simples e exato para o mesmo conjunto de dados.




Fonte: Norvig (2002).

de técnicas de aprendizado supervisionado são Regressão e Regressão Logística, KNN, Árvore de Decisão e Floresta Aleatória (HASSAN et al., 2021).

- **Aprendizado não supervisionado:** O aprendizado não supervisionado usa os fatores latentes nos dados para concluir a relação entre os dados e a tarefa de aprendizado correspondente, e não há necessidade de marcar os dados (YAN et al., 2018). Possui dados não rotulados que o algoritmo precisa tentar entender por conta própria, ou seja, consiste em aprender com padrões de entradas para os quais os valores de suas saídas não são especificados (NORVIG, 2002). Exemplos de aprendizado não supervisionado incluem o algoritmo K-means e o algoritmo Apriori (HASSAN et al., 2021). A Figura 11, mostra um exemplo de aprendizado não supervisionado por agrupamento.

Figura 11 – Exemplo de aprendizado não supervisionado.




Fonte: Adaptada de Yan et al. (2018).

- **Aprendizado semissupervisionado:** É a mistura dos dois tipos de algoritmos

apresentados anteriormente. Os métodos de aprendizado semi-supervisionados melhoram a eficácia dos métodos de aprendizado com o uso de dados não rotulados, quando apenas uma pequena quantidade de dados rotulados está disponível (AGGARWAL, 2015).

Figura 12 – A) Camada greedy de aprendizado. B) Modelo híbrido de Rede de Crenças Profundas ou *Deep Belief Network (DBN)* após aprendizado greedy. As duas camadas superiores formam a máquina de Boltzmann restrita (RBM) e as inferiores uma rede direta de crença.



Fonte: Payton et al. (2016).

Esse tipo de aprendizado é muito usado também na detecção de fraudes para rotular os dados que não possuem rótulos para então usar o aprendizado supervisionado. Um exemplo desse algoritmo é a Rede de Crenças Profundas ou *Deep Belief Network* (Figura 12), na qual é utilizada uma parte do modelo de forma não-supervisionada e outra supervisionada. Consiste em várias máquinas de Boltzmann restritas (RBMs) uma composição de redes simples e não supervisionadas (Figura 12 - A), um RBM tem uma única camada de unidades ocultas que não estão conectadas umas às outras e possuem conexões simétricas e não direcionadas a uma camada de unidades visíveis (HINTON; OSINDERO; TEH, 2006).

Um modelo híbrido é estabelecido empilhando RBMs, conforme ilustrado na (Figura 12 - B). Esse modelo híbrido é chamado de rede de crenças profundas

(DBN), cuja função de probabilidade é dada por:


$$p(v, h_1, h_2, \dots, h_L) = p(h_{L-1}, h_L) p(v|h_1) \prod_{l=2}^{L-1} p(h_{l-1}|h_l), \quad (2)$$

Onde L denota o número total de camadas. V e H são os números de unidades visíveis e ocultas, respectivamente. Agora, deixe $D = h_1, h_2, \dots, h_L$ denotam todo o conjunto de camadas ocultas no DBN, então

$$p(v, D) = p(v, h_1, h_2, \dots, h_L) \quad (3)$$

- **Aprendizado por reforço:** Veja na Figura 13 como funciona o algoritmo. As duas partes mais importantes no aprendizado por reforço são o modelo e o ambiente (Huawei Technologies Co., 2023). O ambiente apresenta duas condições; o estado s_t e a recompensa ou punição r_t , que criam o modelo capaz de gerar diferentes ações. Devido à repetição desse ciclo, o modelo aprende a tomar a melhor decisão guiado pela obtenção de recompensas e também evitando aquelas decisões que levam à punição. Portanto, o objetivo do aprendizado por reforço é encontrar uma estratégia de ação para maximizar o valor da função de recompensa e minimizar a função de punição (Huawei Technologies Co., 2023).

Figura 13 – Algoritmo de aprendizado por reforço.



Fonte: Adaptada de Huawei Technologies Co. (2023).

Um exemplo de aprendizado por reforço é o processo de decisão de Markov, onde a máquina normalmente é treinada para ordenar e categorizar opções explícitas (HASSAN et al., 2021). Quer dizer, a probabilidade de algo acontecer depende diretamente do resultado obtido no evento anterior.

3.5.2 Aprendizado Profundo (DL)


O aprendizado profundo é um conjunto de algoritmos de aprendizado de máquina. Com a ajuda do aprendizado profundo, pode classificar, prever, agrupar e extrair funções; se pode colocar valores de pixel para cada imagem e continuar iterando sobre todas as imagens (MANASWI, 2018b).

As técnicas derivadas do aprendizado de máquina permitem que os computadores aprendam, enquanto o aprendizado profundo gera modelos de redes neurais artificiais que tentam imitar o funcionamento do cérebro humano, permitindo que aprendam com dados e melhorem seu aprendizado por meio de experiências (FRANCO; RAMOS, 2019).

DNN: Uma rede neural profunda é uma rede neural artificial que consiste em mais de três camadas; Ele mescla inerentemente o processo de extração de recursos com a classificação de aprendizado usando máquina de vetores de suporte difuso e permite a tomada de decisões (YUVARAJ et al., 2020).

CNN: Uma rede neural convolucional é um tipo de rede neural artificial; Consiste em camadas convolucionais, camadas de agrupamento (*pooling* em inglês) e camadas totalmente conectadas (*fully connected* em inglês) ver Figura 14. A camada *Dropout* é outro recurso importante da CNN. A imagem é a entrada da rede neural e o mapa de recursos é a saída da camada convolucional ou da camada de agrupamento da rede neural. A imagem está alinhada com o brilho dos três canais RGB, valorizados de 0 a 255 (Huawei Technologies Co., 2023). A operação de convolução na


Figura 14 – Estrutura simplificada de uma rede neural convolucional.



Fonte: Barbosa et al. (2021).

Figura 15, mostra que até 3x3 regiões diferentes podem ser particionadas em uma matriz quadrada 5x5, e a forma dessas regiões é idêntica ao núcleo de convolução. Portanto, a dimensão do mapa de recursos é 3x3. A camada de


Figura 15 – Exemplo de operação de convolução.



Fonte: Huawei Technologies Co. (2023).

agrupamento funciona como uma ferramenta de redução de dimensionalidade, agrupando as unidades próximas e reduzindo o tamanho dos mapas de recursos (Huawei Technologies Co., 2023). Na Figura 16, a camada de *max pooling* divide o mapa de recursos em vários fragmentos retangulares e assume o valor máximo de cada fragmento como o valor característico de toda a região. A camada totalmente

Figura 16 – Um exemplo de operação de agrupamento.




Fonte: Huawei Technologies Co. (2023).

conectada é normalmente usada para a saída da rede neural convolucional. ou seja, classificar as categorias a que pertencem os objetos. Neste caso, estaria informando se a imagem contém ou não carrapatos.

Dropout consiste em descartar aleatoriamente uma parte da saída dos neurônios durante a fase de treinamento. Ao descartar aleatoriamente a saída, o *Dropout* cria uma série de sub-redes com diferentes estruturas (Huawei Technologies Co., 2023). Como mostra a Figura 17, as sub-redes convergem de uma certa maneira na mesma rede neural profunda. Enquanto o modelo está em execução, a inteligência coletiva

Figura 17 – Um exemplo de como funciona a camada *Dropout*.



Fonte: Huawei Technologies Co. (2023).

de todas as sub-redes treinadas é aproveitada, de modo que as saídas dos neurônios não são mais descartadas.

RNN: Uma rede neural recorrente é um tipo de rede neural que captura informações dinâmicas (como vídeo, áudio e frases) em dados serializados conectando nós periodicamente na camada oculta para classificar os dados serializados (Huawei Technologies Co., 2023).

Neste trabalho, a CNN *YOLOv5* foi usado para detectar carrapatos em imagens usando os dados de anotação obtidos por meio de *labelimg*. Os notebooks *Google Colab* são recursos importantes para criar espaços de trabalho dinâmicos e sem restrições em termos de sistema operacional, instalação da linguagem de programação *Python* (LUPPICHINI; BINI; GIANNECCHINI, 2023). A abordagem *YOLOv5* foi retreinada no ambiente de desenvolvimento *Google Colab*, e o código foi desenvolvido na linguagem *Python*.

3.6 Métricas de avaliação de modelos

Depois de inserir a CNN nos conjuntos de dados de entretenimento, deve-se avaliar o desempenho da rede. Idealmente, os dados são separados em conjuntos de dados de entretenimento e teste. Tudo com o fim de avaliar e provar que o conjunto de dados está bem modelado (MANASWI, 2018a).

- Métricas de avaliação de modelos de regressão:

- **Erro médio absoluto (MAE):** Supondo que os verdadeiros valores alvo do exemplo de teste sejam $y_1, y_2, \dots, y_m$ e os valores previstos correspondentes sejam $\hat{y}_1, \hat{y}_2, \dots, \hat{y}_m$, então o MAE é definido da seguinte forma:

$$MAE = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i| \quad (4)$$

O valor MAE é não negativo, e quanto mais próximo de 0, melhor o desempenho do modelo (Huawei Technologies Co., 2023).

- **Erro quadrático médio (MSE):** Supondo que os verdadeiros valores alvo do exemplo de teste sejam $y_1, y_2, \dots, y_m$ e os valores previstos correspondentes sejam $\hat{y}_1, \hat{y}_2, \dots, \hat{y}_m$, então o MSE é definido da seguinte forma:

$$MAE = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (5)$$

O valor MSE é não negativo, e quanto mais próximo de 0, melhor o desempenho do modelo (Huawei Technologies Co., 2023).

- **Coefficiente de correlação (r):** O coeficiente de correlação linear ou r de Pearson só pode ser calculado mediante algumas características de X e Y, onde a principal delas é que ambas sejam variáveis contínuas (ALVARES, 2020). Este coeficiente, toma valores entre -1 e 1, onde:

- Os valores próximos a **-1** indicam uma forte correlação linear **negativa** entre X e Y;
 - Os valores próximos a **1** indicam uma forte correlação linear **positiva** entre X e Y;
 - Os valores próximos a 0 indicam uma fraca correlação linear entre X e Y.
- **Coefficiente de determinação (r^2):** O coeficiente de determinação mede a proporção da variação total que é explicada pelo modelo de regressão. Este coeficiente depende em grande medida da relação linear entre a variável resposta e as variáveis explicativas, pelo que só é válido para comparação de modelos de regressão linear. Sua faixa de valores é definida entre 0 e 1, onde o modelo com r^2 mais próximo de 1 é considerado a melhor opção. Em um modelo de regressão linear simples, o coeficiente de determinação pode ser obtido pelo quadrado do coeficiente de correlação (ALVARES, 2020).

Tabela 1 – Matriz de confusão binária.

	Total da População	Dados Reais Observados	
		Condição = Verdadeiro	Condição = Falso
Predição do Modelo	Predição da condição = Verdadeiro	Verdadeiro Positivo (VP)	Falso Positivo (FP)
	Predição da condição = Falso	Falso Negativo (FN)	Verdadeiro Negativo (VN)

Fonte: Smyth (2001).

- Métricas de avaliação de modelos de classificação:

- **Matriz de confusão:** Na matriz de confusão existem rótulos da classe real observada para as situações de verdadeiro e falso, além dos rótulos para a classe de predição também com as situações de verdadeiro e falso (CECHINEL; CAMARGO, 2020). O desempenho preditivo do modelo pode ser descrito por meio de uma matriz quadrada de ordem 2 e que é denominada de matriz de confusão binária; Veja na Figura 1, que existem quatro combinações possíveis para os resultados de previsão do modelo de classificação. Os valores de Verdadeiro Positivo (VP) e Verdadeiro Negativo (VN) correspondem às respostas corretas do modelo, e os valores de Falso Positivo (FP) e Falso Negativo (FN) correspondem às respostas incorretas.
- **Acurácia geral:** A acurácia é uma medida importante para observar a qualidade de um modelo (CECHINEL; CAMARGO, 2020), é a capacidade de generalização do modelo, também conhecida como a previsão da acurácia do modelo que lida com dados de negócios reais (Huawei Technologies Co., 2023). É medida pela quantidade de acertos de classificação cometidos dividido pelo número total de casos na amostra utilizada para o teste (YE, 2003). Considerando a matriz de confusão apresentada acima, a acurácia geral pode ser definida pela fórmula (6) (CECHINEL; CAMARGO, 2020);

$$Acuraciageral = \frac{VP + VN}{VP + FP + FN + VN} \quad (6)$$

- **Precisão:** A precisão descreve a proporção de documentos verdadeiramente

relacionados ao assunto entre todos os documentos recuperados (Huawei Technologies Co., 2023). Ou seja, representa a proporção entre a quantidade de casos que foram corretamente classificados como positivos e a quantidade de exemplos classificados como positivos, sejam eles corretos ou não (CECHINEL; CAMARGO, 2020).

$$Precisao = \frac{VP}{VP + FP} \quad (7)$$

- **Recall:** O recall descreve os documentos recuperados relacionados ao assunto da pesquisa e a proporção de todos os documentos relacionados na biblioteca (Huawei Technologies Co., 2023). Assim, o recall representa a proporção entre a quantidade de casos que foram corretamente classificados como positivos (VP) e a quantidade total de casos positivos (VP + FN) (CECHINEL; CAMARGO, 2020), então:


$$Recall = \frac{VP}{VP + FN} \quad (8)$$

- **F_1 value:** A pontuação F_1 é a média harmônica da precisão e recall. O valor mais alto possível de um F-score é 1, indicando precisão e recall perfeitos, e valores desfavoráveis se a precisão e recall são 0 ou próximos de 0 (Huawei Technologies Co., 2023).

$$F_1value = \frac{2 * precisao * recall}{precisao + recall} \quad (9)$$

- **Curva ROC:** Um espaço ROC é uma representação bidimensional do desempenho de um classificador binário. Este espaço bidimensional é projetado em dois eixos, ambos com intervalo entre [0-1], sendo no eixo x representada a taxa de falsos positivos, ou sensibilidade, e no eixo y a taxa de verdadeiros positivos, ou complemento da especificidade (BRADLEY, 1997). O *Receiver Operating Characteristic* (**ROC**) é comumente usado a partir da leitura do *Area Under the Curve* (**AUC**)(Figura 18). O ponto nas coordenadas (0,1) representa um classificador perfeito, que não aponta para falsos positivos. Um classificador binário aleatório, por outro lado, seria colocado em uma linha diagonal conectando os pontos (0,0) e (1,1) (CECHINEL; CAMARGO, 2020)(ver Figura 19); Cumprindo que $y=x$. O

Figura 18 – Área sob a curva (AUC).



Fonte: Cechinel and Camargo (2020).


modelo com a maior Área Sob a Curva pode ser considerado o mais eficaz, e o limiar ótimo para o modelo está mais próximo do canto superior esquerdo do gráfico, o que representaria o classificador perfeito no ponto (0,1) (KUHN; JOHNSON, 2013).

3.7 Ferramentas

Este capítulo apresenta uma breve descrição das ferramentas mais utilizadas nas diversas investigações encontradas durante a revisão sistemática da literatura e como elas foram utilizadas neste trabalho.

3.7.1 Python

A linguagem de programação Python foi concebida durante a última parte da década de 1980 e sua implementação começou em 1989 por seu autor Guido van Rossum (MALLOY; POWER, 2019). Python é conhecido por ser fácil de ler e escrever, permitindo que os desenvolvedores trabalhem rapidamente e integrem sistemas com mais

Figura 19 – Função $y=x$.

Fonte: Próprio autor (2023).

eficiência (TOAL et al., 2016). Python inclui suporte para Unicode, coleta de lixo, bem como elementos de programação procedurais, funcionais e orientados a objetos (MALLOY; POWER, 2019). O aprendizado profundo com aplicativos desenvolvidos em Python abrange tópicos como *chatbots*, processamento de linguagem natural e reconhecimento facial e de objetos (MANASWI, 2018a). O objetivo deste trabalho é usar Python para projetar o código usando as técnicas e algoritmos necessários para criar o programa capaz de realizar a detecção e contagem de carrapatos em imagens. Python é multiplataforma e possui inúmeras bibliotecas que permitem realizar diferentes funcionalidades.

3.7.2 *Tensorflow*

O *Tensorflow* é uma biblioteca de software de código aberto projetada para aprendizado profundo por meio da computação de gráficos de fluxo de dados (JIA et al., 2018). O *Tensorflow* foi lançado pelo Google em 2016, como um conjunto de ferramentas para desenvolver algoritmos de aprendizado de máquina e mineração de dados, para atender às necessidades de sistemas capazes de construir e treinar redes neurais para detectar e decifrar padrões e correlações, análogo ao aprendizado e raciocínio usado por humanos (XIE et al., 2021). Todas as plataformas de ambientes Python podem suportar o *Tensorflow* (Huawei Technologies Co., 2023). O *Tensorflow* oferece suporte a

DNN, CNN e RNN em sistemas com várias unidades de processamento gráfico (GPUs) (SEETALA; BIRDSONG; REDDY, 2019). O Tensorflow será usado neste trabalho para processamento de imagens a fim de construir e treinar redes neurais convolucionais para encontrar padrões em imagens.

3.7.3 Keras

Keras é uma biblioteca de alto nível para aprendizado profundo, escrita em Python, que também pode ser utilizada com o *Tensorflow*. Permite desenvolver conceitos básicos de aprendizado profundo, como camadas para redes neurais, enquanto cuida do âmago da questão de tensores, formas e detalhes matemáticos (MANASWI, 2018b).

3.8 Trabalhos Correlatos


Foram encontrados 164 trabalhos relacionados, dos quais 43 atenderam aos critérios de inclusão foram aceitos. Além disso, os trabalhos foram submetidos a uma avaliação de qualidade, sendo analisados se tiverem respondido positivamente a pelo menos 2 de 3 das seguintes perguntas: *o trabalho usa contagem automática?; o trabalho cita ferramentas e técnicas utilizadas?; o trabalho foi publicado nos últimos 4 anos?*.

A Figura 20, apresenta a quantidade de trabalhos em cada etapa desta revisão. A Figura 21, apresenta o número de referências selecionadas/aceitas por base bibliográfica e a Tabela 2, apresenta os trabalhos selecionados pelo protocolo utilizado. A seguir é feita uma análise de cada um dos 43 trabalhos selecionados nesta revisão.

Rahnemoonfar et al. (2019) propuseram um novo modelo portátil baseado em ciclos, *DisCountNet*, é uma rede convolucional de dois estágios que usa o mapa de calor e as teorias de rede de detecção para fornecer um design simples e eficaz. Tem a limitação de detectar e contar objetos altamente ocluídos, o que pode ser benéfico para o nosso trabalho.

Wu et al. (2019) propuseram um método eficiente que usa visão de máquina para contar as mudas de arroz em uma imagem digital com precisão superior a 93%. É usada uma rede de regressão (Rede Básica) inspirada em uma rede neural profunda totalmente convolucional para regredir o mapa de densidade e estimar o número de mudas de arroz

Figura 20 – Revisão sistemática da literatura.




Fonte: Próprio autor (2022).

para uma determinada imagem de veículo aéreo não tripulado (VANT). Os resultados indicam que o método proposto é uma alternativa eficiente para contagem em larga escala de mudas de arroz e oferece uma nova oportunidade para estimativa de produtividade.

Chen, Kung and Hwang (2019) apresentaram as diferentes técnicas de aprendizado profundo e como elas são usadas para aplicações agrônômicas e especifica que a combinação de técnicas de aprendizado supervisionado e não supervisionado pode fornecer estimativa e previsão precisas para aplicações agrônômicas.

Chen et al. (2019) desenvolveram um sistema de detecção automática para flores de morango. Ele usou um R-CNN, um modelo de rede neural profunda de última geração, para a detecção e contagem do número de flores, morangos maduros e morangos verdes. O modelo foi verificado através de imagens obtidas com VANT a 2m e comparado com uma contagem manual. O coeficiente de determinação (r^2) do modelo de *deep learning* entre os rendimentos reais e estimados foi de 0,89. Apesar do modelo ter sofrido um desafio na contagem de frutos imaturos pelo fato de confundi-los com as folhas. O modelo

Figura 21 – Quantidade de trabalhos selecionados e aceitos em cada base de dados.



Fonte: Próprio autor (2022).

apresentou precisões de contagem superiores a 80%, portanto, o método mostrou que pode ser utilizado para contar o número de flores de forma eficaz.

Doering et al. (2020) apresentaram uma técnica capaz de detectar células infectadas com o parasita da malária entre células sanguíneas saudáveis; um conjunto de dados foi usado para verificar as características básicas das células infectadas, uma CNN foi treinada para contar células infecciosas usando a detecção de arestas de *Canny*; e a transformada de *Hough* para a detecção de círculos. A rede foi treinada por 3 épocas e observou uma alta diferença média de 0,78 células por imagem entre os rótulos de validação e as previsões da rede. portanto, concluiu-se que não está pronto para uso imediato para fins médicos.

Evangelina et al. (2020) apresentaram um detector de objetos *Faster R-CNN* sintonizado para detecção e contagem automática de linfócitos em tecido canceroso. Eles alcançaram uma precisão do classificador para caixas delimitadoras de 98% com *Resnet-101*, o erro médio na contagem de linfócitos para todas as regiões de interesse foi insignificante. demonstrando que o modelo é eficiente e produz bons resultados.

Campoverde and Barros (2020) criaram um rastreador de objetos de DNN para mobilidade urbana com um dispositivo Android. Os autores treinam novamente o modelo *Single Shot Detector (SSD)* e usa as estruturas *Tensorflow mobile* versus *Tensorflow lite*. Os resultados mostraram que o *Tensorflow mobile* é mais lento que o *Tensorflow lite* com 120ms e 900ms respectivamente, em termos de tempo de inferência. Além disso, o modelo retreinado permite a integração de novos cenários, melhorando a taxa de detecção.

Tu et al. (2020) propuseram um método aprimorado baseado em uma abordagem R-CNN baseada em região mais rápida em várias escalas (MS-FRCNN) usando imagens RGB-D, para a detecção e contagem de maracujá. Em comparação com o detector

R-CNN mais rápido de imagens RGB-D, o **recall**, a precisão e a pontuação F1 do método MS-FRCNN aumentaram de 0,922 para 0,962, 0,850 para 0,931 e 0,885 para 0,946, respectivamente. Além disso, o método MS-FRCNN melhora efetivamente a detecção de maracujás pequenos, alcançando 0,909 da pontuação F1.

Valente et al. (2020) propuseram um método para identificar e contar plantas de espinafre a partir de imagens de VANT usando visão artificial (*Excess Green Index* e o método Otsu) e transferindo a informação através da CNN. Os resultados mostraram uma precisão de 95% para uma resolução espacial de 8 mm/pixel em uma área de até 172m². Além disso, quando a resolução espacial diminui em 50%, o erro de contagem adicional máximo alcançado é de 0,7%. O estudo mostra que é possível contar plantas individuais usando imagens de VANT.

Cao et al. (2020) propuseram o algoritmo *EfficientDet* para detectar a imagem da espiga de trigo. Os resultados experimentais mostram que o modelo pode reconhecer com rapidez e precisão imagens de espigas de trigo com diferentes densidades sob várias condições de iluminação. A taxa de acurácia final atinge 92,92% e o tempo de teste de uma única folha é de 0,2s. Ao testar o método de contagem com 20 imagens de espigas de diferentes densidades, o índice médio de acurácia atingiu 95,30%.

Hosseini, Chen and Jablonski (2020) desenvolveram uma ferramenta automatizada baseada na técnica de aprendizado profundo e no modelo *Mask R-CNN* para analisar grandes conjuntos de dados de imagens de microscopia eletrônica de transmissão (TEM) e quantificar células da retina com alta velocidade e precisão. O modelo de contagem automática de células foi mais de 80% acurácia na detecção e categorização de células.

Wei et al. (2020) propuseram um método de contagem automática para ferramentas ferroviárias baseado em aprendizado profundo. O método baseia-se na obtenção de imagens do kit de ferramentas quando ele é entregue ao trabalhador e quando ele o devolve. Compare as duas imagens e identifique quais ferramentas são necessárias. Os resultados mostraram uma precisão promédio médio (mAp) de 83%.

Haiyan et al. (2020) projetaram um método de contagem automática chamado pirâmide de características generativas para detecção de panículas (GFP-PD) com base na pirâmide de características e redes antagônicas generativas. O modelo foi treinado e testado com imagens de arroz no campo tiradas da variedade Nanjing 46. A precisão média de contagem de panículas e a precisão média de reconhecimento de panículas de GFP-PD foram 90,82% e 99,05%, respectivamente, que foram 16,69% pontos e 5,15

pontos percentuais acima dos resultados do *Faster R-CNN*.

Mu et al. (2020) construíram um modelo de detecção de tomate para detectar automaticamente tomates verdes intactos, independentemente de oclusões ou estágio de crescimento do fruto, usando abordagens de aprendizado profundo. O modelo de detecção de tomate usou uma rede neural convolucional baseada em região mais rápida (R-CNN) com *Resnet-101* e [transfer learning] do conjunto de dados *Common Objects in Context* (COCO). Ao detectar, contar, localizar e estimar o tamanho do tomateiro no conjunto de dados de teste alcançou alta precisão média de 87,83% e mostrou uma alta precisão de contagem de tomate ($r^2 = 0,87$). Este método apresenta grande potencial para prever maturidade e rendimento de tomate.

Okunev et al. (2020) apresentaram os resultados da aplicação do aprendizado profundo ao reconhecimento automatizado de nanopartículas metálicas depositadas em grafite pirolítico altamente orientado em imagens obtidas por microscopia de varredura de túnel (STM), usando a rede neural *Cascade Mask-RCNN*. Como resultado, a rede neural treinada reconheceu as nanopartículas no conjunto de verificação com uma precisão de 0,93 e um recall de 0,78.

Hosseiny, Rastiveis and Homayouni (2020) propuseram uma estrutura automatizada e totalmente não supervisionada baseada em métodos de processamento de imagem e DL para detecção de plantas em terras agrícolas a partir de imagens de sensoriamento remoto de drones de altíssima resolução. O núcleo desta estrutura é baseado na rede neural convolucional regional mais rápida (R-CNN) com o backbone do *ResNet-101* para detecção de objetos. A eficiência do *framework* proposto foi avaliada por dois conjuntos de imagens diferentes de dois campos de milho, adquiridos por uma câmera RGB montada em drone. Os resultados mostram que o método proposto leva a uma precisão média de contagem de 90,9%.

Tetila et al. (2020) avaliaram três modelos de CNN para contagem de insetos em campos de soja *DenseNet-201*, *Inception-Resnet-v2* e *Resnet-50*. Com três diferentes estratégias de treinamento: 100% de ajuste fino com pesos obtidos do *ImageNet*, uma rede completa com pesos inicializados aleatoriamente e transferência de aprendizado com pesos obtidos do *ImageNet*. A abordagem de classificação obteve o melhor resultado com *DenseNet-201* (acurácia de 94,89 %) usando um ajuste fino de 100%. Para avaliar o desempenho da contagem, a CNN de melhor valor foi usada na tarefa de classificação com as três estratégias *Inception-Resnet-v2*; apresentando acurácia de 90,86%, precisão de 89,19%, F_1 value de 0,90 e MAE de 0,61. Os resultados indicaram que modelos

de aprendizado profundo podem ser usados com sucesso para apoiar especialistas e agricultores no manejo de pragas de insetos em campos de soja.

Yiwen et al. (2020) propuseram uma nova estrutura para contagem de espigas de trigo de campo chamada conexão direta para melhorar o algoritmo do Vggnet, tornando-o mais compatível com a perda de contagem baseada em localização. O modelo tem um bom efeito de reconhecimento nas espigas de trigo que estão presas entre elas. Para espigas de trigo densas, o modelo pode atingir uma taxa de precisão de 90,4%.

Ala'raj and Majdalawieh (2020) propuseram um algoritmo híbrido para contar objetos repetidos na imagem. O algoritmo proposto consiste em duas partes. O sub-algoritmo de correspondência do modelo para reconhecer e/ou localizar objetos específicos em uma imagem e o sub-algoritmo da CNN para filtrar falsos positivos que podem ocorrer durante a avaliação da correspondência. O algoritmo foi avaliado em imagens de microscopia de sangue para contagem de eritrócitos e imagem de campo de camomila para contagem de flores. Para os 2 conjuntos de dados, resultados precisos foram obtidos com uma acurácia de 97%. O algoritmo é capaz de contar imagens modelo em amostras de sangue e distinguir glóbulos vermelhos de outros tipos; que podem ser usados para beneficiar a identificação de carrapatos em imagens.

Wang et al. (2021a) projetaram um sistema automático de contagem de hemácias baseado em microscopia pticográfica de Fourier para adquirir imagens de alta resolução por serem imagens microscópicas de baixa resolução. Além disso, uma CNN especializada é introduzida para realizar a tarefa de contagem automática de glóbulos vermelhos, o que aumenta a eficiência da contagem, mantendo alta precisão.

Zhang et al. (2021) descreveram vários métodos de contagem de microrganismos desde o processamento clássico de imagens até abordagens de aprendizado profundo onde se destaca que o processamento digital de imagens tem sido amplamente utilizado na contagem microbiana em diversos tipos de pesquisa, devido à sua boa tendência de desenvolvimento até o momento da referida investigação.

Wang et al. (2021b) usaram Microscopia Psicográfica de Fourier(MPF) e CNN para contar as células da medula óssea. A microscopia Psicográfica de Fourier(MPF) é uma técnica de imagem computadorizada que tem sido usada para melhorar a qualidade da imagem; No MPF, uma matriz de diodos emissores de luz (LEDs) programáveis que fornecem ondas planas é usada para iluminar sequencialmente o espécime de diferentes ângulos, controlando a saturação das cores e, posteriormente, obtendo uma imagem de alta resolução. Em seguida, uso a estimativa de densidade baseada em CNN para extrair

os recursos, contar e detectar as células na imagem. Os resultados experimentais mostram um bom desempenho apresentando um valor MAE de 0,66 e MSE de 0,67.

Tessema et al. (2021) usaram aprendizado profundo para quantificar células sanguíneas a partir de imagens microscópicas usando o modelo de detecção de objetos *YOLOv2*, utilizado para detecção e contagem de células sanguíneas, após o que foi realizada uma análise quantitativa que apresentou maiores precisões médias em 88%.

Marcelo, Ilao and Cordel (2021) fizeram uma melhoria na contagem e detecção de frutas e hortaliças, uma vez que são comumente camuflados pela cor ou formas que se assemelham no ambiente, usando redes modelo *Faster R-CNN* que foram implementadas usando o *TensorFlow*.

Yang et al. (2021) fizeram uma revisão sobre os modelos utilizados para visão artificial na aquicultura inteligente com ênfase na detecção de peixes e análise do comportamento.

Wu et al. (2021) projetaram um algoritmo para contar caixas de comprimidos automaticamente na aplicação industrial de farmácias inteligentes em tempo real. Este algoritmo usa as características dos espaços entre cuboides e adota uma detecção de linha de Hough aprimorada para identificar os espaços e depois contá-los.

Gouiaa, Akhloufi and Shahbazi (2021) revisaram os artigos que foram publicados na última década sobre métodos de contagem de multidões e forneço uma pesquisa abrangente de técnicas recentes de contagem de multidões e estimativa de densidade com base na CNN.

Ammar, Koubaa and Benjdira (2021) propuseram uma estrutura original de aprendizado profundo para contagem automatizada e geolocalização de palmeiras a partir de imagens aéreas usando CNN. Vários modelos recentes de rede neural convolucional (*Faster R-CNN*, *YOLOv3*, *YOLOv4* e *EfficientDet*) foram aplicados para detectar palmeiras e outras árvores, e realizamos um benchmark completo em termos de precisão média e velocidade de inferência.

Bjerge et al. (2021) apresentaram um sistema portátil de visão computacional capaz de atrair e detectar insetos vivos. Um algoritmo de visão computacional chamado contagem e classificação de mariposas, com base na análise de aprendizado profundo das imagens capturadas, rastreou e contou o número de insetos e espécies de mariposas identificadas.

Lavitt et al. (2021) propuseram um modelo de regressão treinado de ponta a ponta baseado em CNN para fornecer contagem de células para contagem automatizada

de células em imagens microscópicas de linhas celulares de câncer humano. Também propõe o uso do *xResNet*, uma arquitetura convolucional de sucesso com conexão residual, juntamente com o aprendizado de transferência (usando um modelo previamente treinado) para alcançar desempenho em nível humano. Mostrando que o método proposto (aprendizado profundo e aprendizado por transferência) supera os métodos de aprendizado de máquina atualmente utilizados.

Hong et al. (2021) propuseram algoritmos de contagem automatizada de aprendizado profundo usando imagens de armadilhas de feromônio. Método de recorte de imagem foi aplicado para detecção bem sucedida de pequenos objetos na imagem. O desempenho de detecção e contagem foi avaliado e uma precisão de contagem de 95% ou melhor foi mostrada na maioria dos modelos utilizados. O resultado mostrou que o método de contagem de pragas baseado em inteligência artificial proposto neste estudo é adequado para o monitoramento constante e preciso de insetos-praga.

Mekhafi et al. (2021) investigaram o uso de aprendizado profundo para detecção de círculos nas plantações no deserto. Usaram *Mask R-CNN* e *YOLOv3* como linhas de base de detecção. Experimentos mostraram que o *YOLOv3* tende a detectar mais círculos nas plantações e compromete a precisão, enquanto o *Mask R-CNN* é muito mais preciso, embora menos preciso. Em termos de tempo de inferência, o *YOLOv3* ainda é muito mais rápido.

Deng et al. (2021) propuseram um modelo de detecção de kernel para reconhecer e contar automaticamente kernels nos ramos primários de uma panícula de arroz. O modelo usou análise de imagem baseada em CNN, integrando a rede de pirâmide de recursos (FPN) na rede R-CNN mais rápida. O desempenho do modelo de detecção de grãos foi comparado ao do modelo R-CNN original mais rápido e do modelo SSD, e o modelo de detecção de grãos foi considerado mais confiável e preciso.

Gochoo et al. (2021) propuseram um novo sistema que pode rastrear pessoas monitorando suas cabeças e ombros em ambientes complexos e também contar o número de pessoas que entram e saem da cena. As cabeças são detectadas usando a transformada circular de Hough (CHT) e os ombros são detectados usando métodos de simetria baseados em histogramas de gradientes orientados (HOG). Finalmente, as cabeças são contadas usando o julgamento de linha cruzada. Os testes realizados mostraram uma precisão de contagem superior a 98%.

Fukuda, Okuno and Yuki (2021) apresentaram o CROP (*Central Roundish Object Painter*). O método envolve segmentação de imagem usando aprendizado profundo e

a arquitetura da rede neural é uma versão mais profunda do U-Net. CROP identifica diferentes tipos de frutas arredondadas centrais em uma imagem RGB sob variadas condições de iluminação.

Chen and Shang (2022) propuseram um novo modelo de aprendizado profundo eficiente chamado transformador de densidade (DENT) baseado em CNN, para contagem automática de árvores a partir de imagens aéreas. Obteve resultados competitivos e superou os métodos mais avançados.

Kim et al. (2022) propuseram um método automático baseado em câmera para contar o número de porcos que passam por uma zona de contagem. Ou seja, usando uma câmera em um corredor, o método de detecção e rastreamento de objetos de vídeo baseado em aprendizado profundo analisa os fluxos de vídeo e conta o número de porcos que passam pela zona de contagem. O método baseado em aprendizado profundo, chamado *EmbeddedPigCount*, atingiu uma mAp de contagem de 96,95%.

Zhou et al. (2022) apresentaram uma ideia inovadora chamada *ErythroidCounter* baseada em *deep learning*, é composta por módulos de detecção e extração (DEM) seguidos pelo módulo de classificação e contagem (CCM). O DEM adapta o *RetinaNet* para localizar e detectar células eritroides na medula óssea de pacientes com leucemia ou hematopatia, enquanto o CCM é baseado na arquitetura *DenseNet-121* para realizar classificação e contagem. O desempenho do *ErythroidCounter* na classificação alcançou uma precisão de 86,33%, recall de 87,45%, precisão de 87,16% e pontuação F1 de 87,30%. E o desempenho na detecção alcançou precisão de 90,7%, recall de 91,3% e pontuação F1 de 90,9%.

Ruparelia, Jethva and Gajjar (2022) usaram quatro modelos *YOLO* (*YOLOv3*, *YOLOv3-Tiny*, *YOLOv4* e *YOLOv4-Tiny*) treinados no ambiente de GPU do Google Colab. Para a detecção, classificação e contagem de tomates em tempo real e comparou seus desempenhos. Os resultados mostraram que o *YOLOv4* obteve os melhores resultados com precisão média alta de 81,28%, recall de 0,52 e pontuação F_1 de 0,66, enquanto o *YOLOv3-Tiny* apresentou melhor desempenho em quadros por segundo com 26,85.

Inik and Ülker (2022) fizeram a otimização dos parâmetros (GS, ND e PA) utilizados em um método baseado em CNN, para a otimização foram utilizados cinco algoritmos (GWO, ABC, GA, PSO e BWO) para ajustar os parâmetros baseados em CNN. Os resultados mostraram que ABC obteve a melhor perda média de segmentação, o algoritmo PSO obteve o melhor desempenho, a convergência mais rápida entre os algoritmos foi realizada pelo algoritmo BWO. No geral, o desempenho do modelo

baseado em CNN aumentou 8,1% com otimização de parâmetros baseada no valor médio de IoU.

Santos et al. (2022) propuseram um dispositivo de contagem automática de pessoas de baixo custo baseado em um microcontrolador através de dois sensores infravermelhos. O microcontrolador deste projeto foi programado no ambiente *Arduino IDE* que é uma linguagem semelhante a C. Os resultados da contagem mostraram que a precisão do dispositivo ultrapassa 90%.

Alom et al. (2022) propuseram um modelo denominado Rede Recorrente Densamente Conectada (DCRN) para tarefas de classificação, segmentação e detecção de núcleos. Aplicando os modelos *R2U-Net*, UD-Net, eles mostraram resultados 2,6% e 1,7% maiores em termos de pontuação F_1 para tarefas de classificação e detecção de núcleo em comparação com o método baseado em DCNN publicado anteriormente. Para a segmentação do núcleo, o *R2U-Net* apresenta uma precisão média de teste em torno de 91,90%, sendo 1,54% superior ao modelo *U-Net*.

Xia et al. (2022) usaram a arquitetura de detecção sem fio (*CenterNet*) para detectar frutas em sequências de imagens de vídeos coletados no pomar de macieiras e laranjeiras. Os resultados experimentais mostraram que o modelo *CenterNet* pode detectar com sucesso frutas, incluindo maçãs e laranjas, em sequências de imagens e alcançou uma precisão média (mAp) de 0,939 com um IoU de 0,5.

Após a revisão da literatura descobrimos que muitas técnicas foram aplicadas para melhorar os processos de detecção e contagem de objetos, além de conhecer como funcionam, seus resultados e reconhecer como pode ser aplicado neste trabalho.

Tabela 2 – Arquivos aceitos na revisão sistemática.

Arquivo	Autor	Contagem de	Técnica ou ferramenta
[1]	Chen and Shang (2022)	Árvores	DENT
[2]	Alom et al. (2022)	Núcleos microscópicos	DCNN
[3]	Xia et al. (2022)	Maças e laranjas	<i>CenterNet</i>
[4]	Santos et al. (2022)	Perssoas	Microcontrolador com Arduino IDE
[5]	Inik and Ülker (2022)	Imagens médicas	CNN
[6]	Ruparelia, Jethva and Gajjar (2022)	Tomates	<i>YOLO</i>
[7]	Zhou et al. (2022)	Células eritroides	<i>ErythroidCounter</i>
[8]	Kim et al. (2022)	Porcos	<i>EmbeddedPigCount</i>
[9]	Wu et al. (2021)	Cuboides	Transformada de Hough (HT)
[10]	Fukuda, Okuno and Yuki (2021)	Frutas	CROP
[11]	Gochoo et al. (2021)	Perssoas	CHT, HOG
[12]	Deng et al. (2021)	Grãos de arroz	R-CNN
[13]	Mekhalafi et al. (2021)	Círculos nas plantações	<i>Mask R-CNN, YOLOv3</i>
[14]	Hong et al. (2021)	Insetos	DL
[15]	Lavitt et al. (2021)	Células	<i>xResNet</i>
[16]	Bjerge et al. (2021)	Insetos	DL
[17]	Yang et al. (2021)	Peixes	Visão artificial
[18]	Marcelo, Ilao and Cordel (2021)	Frutas	<i>Faster R-CNN</i>
[19]	Tessema et al. (2021)	Células sanguíneas	<i>YOLOv2</i>
[20]	Wang et al. (2021b)	Células da medula óssea	Técnicas de Fourier, CNN
[21]	Wang et al. (2021a)	Glóbulos vermelhos	Técnicas de Fourier, CNN
[22]	Ammar, Koubaa and Benjdira (2021)	Palmeiras	CNN
[23]	Gouiaa, Akhloufi and Shahbazi (2021)	Perssoas	CNN
[24]	Zhang et al. (2021)	Microorganismos	DL
[25]	Haiyan et al. (2020)	Panículas de arroz	GFP-PD
[26]	Tetila et al. (2020)	Insetos	CNN
[27]	Valente et al. (2020)	Plantas de cultivo	CNN
[28]	Wei et al. (2020)	Ferramentas ferroviárias	DL
[29]	Hosseini, Chen and Jablonski (2020)	Células da retina	R-CNN
[30]	Cao et al. (2020)	Espigas de trigo	<i>EfficientDet</i>
[31]	Hosseiny, Rastiveis and Homayouni (2020)	Plantas de cultivo	R-CNN
[32]	Okunev et al. (2020)	Nanopartículas	<i>Mask-RCNN</i>
[33]	Mu et al. (2020)	Tomates	R-CNN
[34]	Ala'raj and Majdalawieh (2020)	Eritrócitos e flores	CNN
[35]	Tu et al. (2020)	Maracujá	R-CNN
[36]	Campoverde and Barros (2020)	Atores urbanos	DNN
[37]	Evangeline et al. (2020)	Linfócitos	<i>Faster R-CNN</i>
[38]	Doering et al. (2020)	Glóbulos vermelhos	CNN
[39]	Yiwen et al. (2020)	Espigas de trigo	CNN
[40]	Wu et al. (2019)	Mudas de arroz	CNN
[41]	Rahnemoonfar et al. (2019)	Gado e vida selvagem	<i>DisCountNet</i>
[42]	Chen et al. (2019)	Morangos	DNN
[43]	Chen, Kung and Hwang (2019)	Ninfas de pulgões, fungos	DL

Fonte: Próprio autor (2022).

4 ABORDAGEM PROPOSTA

Este capítulo apresenta a abordagem proposta. Primeiramente foi descrito o processo de anotação dos carrapatos nas imagens, seguido da arquitetura utilizada para a criação do modelo e o processo de treino e teste. Na sequência, são abordados os resultados da aplicação do modelo e discussão das métricas de avaliação.


4.1 Anotação

YOLO modela o problema de detecção como um problema de regressão dividindo a imagem de entrada em n sub-imagens. Cada sub-imagem prevê B (caixas delimitadoras ou “*bounding boxes*”) contendo as coordenadas t_x (centro do objeto em X), t_y (centro do objeto em Y), t_w (largura do objeto em X), t_h (largura do objeto em Y) e uma pontuação de “objetividade” [p_o] mostrando se a célula da grade contém um objeto ou não. Cada célula da grade também prevê uma probabilidade de classe [$p_1|p_2|...|p_c$] para a classe do objeto associado a essa célula. Portanto, para cada célula da grade, *YOLO* prevê parâmetros $B \times 5$ (este número corresponde às quatro variáveis coordenadas e à pontuação de objetividade) e probabilidades de classe C (veja a Figura 22).

Para a anotação dos carrapatos nas imagens, foi utilizada a ferramenta de rotulagem *labelImg* versão 1.8.6, onde foi definida uma única classe de rotulagem “0” que representa a existência de carrapatos na imagem (coluna 1 na figura 23). Esta ferramenta converte os dados de rotulagem de cada imagem em arquivos de texto plano em formato .TXT com as coordenadas da caixa delimitadora dos objetos anotados na imagem (t_x, t_y, t_w, t_h) colunas 2, 3, 4, 5; então o arquivo é salvo com o mesmo nome da imagem (figura 23). Este padrão de nomeação da imagem e do arquivo de anotação permite o treinamento do algoritmo para identificação de carrapatos nas imagens, conforme Figura 24.

Foram anotados 795 carrapatos nas 48 imagens sorteadas. A Figura 25 mostra a distribuição da quantidade de carrapatos por imagem. Há duas imagens que são consideradas *outliers*, com 62 e 125 carrapatos. 25% das imagens anotadas tinham entre 1 e 5 carrapatos. Outros 50% das imagens tinham entre 5 e 21 carrapatos. As 25% imagens restantes continham 21 carrapatos ou mais. Como 75% das imagens contém poucos carrapatos, menos de 21, há uma maior variabilidade em relação aos animais, sendo esta situação preferível em relação a uma situação de muitos carrapatos em poucas imagens. O teste de Shapiro Wilk apontou que a quantidade de carrapatos por imagem

Figura 22 – Saída *YOLO* final que consiste em coordenadas de caixa, pontuações de objetividade e pontuações de classe.



Fonte: Adaptada de Omid et al. (2021).

Figura 23 – Arquivo .TXT com as coordenadas de cada carrapato na imagem anotada.

20191127_082920.xml.txt

```
0 0.539567 0.076187 0.018411 0.018653
0 0.520672 0.028343 0.015504 0.012597
0 0.488372 0.094234 0.019380 0.019864
0 0.515988 0.796754 0.013889 0.010174
0 0.577358 0.680111 0.020349 0.012355
0 0.531654 0.775557 0.019380 0.013808
0 0.481428 0.134811 0.018411 0.015262
0 0.546027 0.084545 0.022287 0.011628
```

Fonte: Próprio autor (2023).


tem uma distribuição normal.

Tabela 3 – Estatística descritiva da quantidade de carrapatos por imagem.

Mínimo	Q_1	Moda	Mediana	Média	Q_3	Máximo
1	5	7	8,5	16,56	21	125


Fonte: Próprio autor (2023).

Figura 24 – Anotação de carrapatos com labelImg.



Fonte: Próprio autor (2023).

Figura 25 – Distribuição da quantidade de carrapatos por imagem.




Fonte: Próprio autor (2023).

Tabela 4 – Estatística descritiva das dimensões das caixas delimitadoras das anotações.

	Mínimo	Q_1	Mediana	Média	Q_3	Máximo
Largura	0.002907	0.009690	0.013566	0.013933	0.017119	0.034157
Altura	0.004199	0.011628	0.015019	0.017465	0.021318	0.067829

Fonte: Próprio autor (2023).

Figura 26 – Distribuição das dimensões das caixas delimitadoras das anotações.




Fonte: Próprio autor (2023).

4.2 Arquitetura

O *YOLO* usa aprendizado profundo e CNN para detectar objetos com base em diferentes técnicas de segmentação de imagem, já tendo sido utilizado em problemas de classificação e contagem de objetos (MEKHALFI et al., 2021; AMMAR; KOUBAA; BENJDIRA, 2021; TESSEMA et al., 2021; RUPARELIA; JETHVA; GAJJAR, 2022). A estrutura da rede *YOLO* (Figura 27), consiste em três partes principais: coluna vertebral, pescoço e a cabeça da rede. A primeira é responsável por extrair características da imagem em diferentes escalas. A segunda combina as características extraídas para se preparar para a previsão. A terceira usa as características do pescoço para prever a caixa e a classe de cada objeto na imagem (OMIDI et al., 2021).

Neste trabalho, a rede neural baseada na rede *You Only Look Once (YOLO)* v5 foi retreinada para detectar e contar carrapatos em imagens. O *YOLOv5* melhora a capacidade de generalização da rede e, ao mesmo tempo, reduz sua complexidade computacional em comparação com versões anteriores do *YOLO* (GKOUZIONIS et al.,


Figura 27 – Estrutura da rede YOLO.



Fonte: Omid et al. (2021).

2023). A arquitetura do modelo é apresentada na Figura 28. O YOLOv5 usa uma *CrossStage Partial Network (CSPNet)* (LIU et al., 2018) como a espinha dorsal do modelo e uma *Path Aggregation Network (PANet)* (WANG et al., 2020) como o pescoço para agregação de características. Esses novos aprimoramentos fornecem uma melhor extração de características e um aumento significativo no mAPscore (DLUŽNEVSKIJ; STEFANOVIČ; RAMANAUSKAITĖ, 2021).

Figura 28 – Estrutura da rede YOLOv5.



Fonte: Dlužnevskij, Stefanovič and Ramanauskaitė (2021).


4.3 Treinamento e teste

Foram selecionadas aleatoriamente 48 imagens que continham carrapatos de diferentes tamanhos e foi realizada a anotação dos carrapatos nestas imagens. Após a anotação nas imagens, foi realizada um aprendizado por transferência (ou *transfer learning* em inglês) que é uma técnica de aprendizagem supervisionada, pois permite treinar modelos com menos dados rotulados, reutilizando modelos que já foram treinados com grandes conjuntos de dados no conjunto de dados *Common Objects in Context* (COCO) (CORNUÉJOLS; MURENA; OLIVIER, 2020). O modelo pré-treinado *YOLOv5* foi utilizado como base de partida para o subsequente processo de treinamento com imagens de bovinos infestados com carrapatos. A opção pelo uso da técnica de *transfer learning* foi feita por permitir o reconhecimento de novos objetos com um número menor de imagens. Caso não fosse utilizado o *transfer learning*, a base de 48 imagens deveria ser amplamente expandida para se obter um resultado similar ao aqui obtido. Durante o treinamento, as imagens foram divididas em treino e teste, nas proporções de 80% e 20%. O treinamento foi realizado durante 100 épocas, decorrendo um tempo de 2,871 horas. O modelo criado, com seus 20.852.934 parâmetros, ocupou um total de 45,4MB.

4.4 Resultados e Discussão

Após a avaliação das métricas, foi evidenciado que o modelo detecta carrapatos com 0,91 de acurácia. Os valores de perda, ou *loss*, reduziram nos dados de treino e estavam atingindo uma tendência de estabilidade nos dados de validação, o que justifica a parada próxima a 100 épocas. Da mesma forma, recall e mAP estão pouco acima de 0,8. Ou seja, a abordagem apresenta resultados confiáveis para a detecção e contagem de carrapatos. Tais métricas são apresentadas na Figura 29. A taxa de verdadeiros positivos do modelo é 0,91, e também mostra uma taxa de falsos negativos de 0,09. Ou seja, 9% dos carrapatos na imagem não foram reconhecidos pelo modelo como carrapatos. Por outro lado, a taxa de verdadeiros negativos, que é considerada como o *background* da imagem, foi de 1,0, o que permite deduzir que, nas imagens de teste, o modelo não considerou o animal ou o ambiente como carrapatos (veja a Figura 30).

Figura 29 – Resultados de avaliação das métricas.




Fonte: Próprio autor (2023).

4.4.1 Utilização do Modelo

Nas imagens de validação a seguir, pode-se observar que o modelo está identificando os carrapatos nas imagens (Figura 31). Na imagem superior esquerda, o modelo está detectando o carrapato apesar de corresponder a um bovino de pelagem mais clara. Na imagem inferior esquerda, é possível verificar que o modelo ignora as moscas encontradas no animal, sem confundi-las com carrapatos. Da mesma forma, as feridas na pele do animal na imagem inferior direita estão sendo corretamente ignoradas. Ou seja, mesmo que as imagens apresentem mais figuras como vegetação, madeira, feridas ou sujeira que possam causar confusão, o modelo não está identificando outros objetos nas imagens como carrapatos. Veja que embora as quatro imagens apresentem diferenças devido à luminosidade, espaços onde as imagens apresentam sombras ou não, os carrapatos continuam sendo detectados pelo modelo.

O modelo foi também testado em um vídeo do YouTube (link: <<https://www.youtube.com/watch?v=2AeuIfdgQWs>>) que corresponde a um cachorro infestado de carrapatos. Apesar de imagens de cachorros não terem sido utilizadas para treinar o modelo, ele foi capaz de detectar carrapatos neste animal (figuras extraídas do vídeo 32, link: <<https://www.youtube.com/watch?v=CuY4OT1ZnIM>>). O modelo também foi testado em um vídeo do YouTube (link: <https://www.youtube.com/watch?v=ME_GuezmSAE>) de um bovino de outra raça, com diferentes distâncias da câmera (figuras

Figura 30 – Matriz de confusão.



Fonte: Próprio autor (2023).

extraídas do vídeo 33, link: <<https://www.youtube.com/watch?v=Yg4TuYQsy8o>>). Nas figuras 32 e 33 alguns carrapatos não estão sendo detectados pelo modelo, possivelmente porque o modelo não foi treinado com um grande número de carrapatos acumulados na mesma imagem.

Figura 33 – Teste de modelo em um bovino de outra raça.



Fonte: Próprio autor (2023).

5 CONCLUSÕES

A pecuária é uma das atividades mais importantes para a economia brasileira. A demanda e a produção de proteína bovina estão aumentando devido ao crescimento populacional, mudanças no estilo de vida e aumento da renda da população. Carrapatos causam perdas econômicas significativas na pecuária, tanto como parasitas hematófagos quanto como vetores de patógenos e toxinas. Para contribuir com a eficiência dos métodos de controle, é necessário identificar e quantificar a infestação em sua fase inicial. De maneira alinhada com a evolução tecnológica do agronegócio e com o crescente uso da Inteligência Artificial, neste trabalho foi desenvolvido um modelo capaz de detectar automaticamente carrapatos por meio de imagens para contribuir com os métodos de controle na fase inicial de infestação do rebanho.

Para desenvolver este modelo, foram coletadas, nas instalações da Embrapa Pecuária Sul, 500 imagens de bovinos da raça Brangus submetidos a diferentes níveis de infestação. Para treinar o modelo foram selecionadas aleatoriamente 48 imagens de bovinos que tiveram seus carrapatos rotulados através da ferramenta *labelImg*. Na sequência, as imagens anotadas foram divididas nas proporções de 80% e 20% para treinamento e teste respectivamente. A arquitetura de detecção de objetos *YOLOv5* pré-treinada foi utilizada. O modelo foi retreinado, durante 100 épocas, dentro do ambiente de desenvolvimento *Google Colab*, com as imagens de bovinos infestados. Como resultado, o modelo desenvolvido neste trabalho foi capaz de detectar carrapatos em imagens de bovinos com acurácia de 0.91. Os resultados obtidos mostram que a abordagem proposta é capaz de responder positivamente ao problema de pesquisa que foi vislumbrado no início deste trabalho.

A principal limitação deste trabalho é relativa à base de imagens de treinamento. As imagens utilizadas foram de uma única raça, com pelagem preta, que contempla o cenário mais difícil para a detecção do carrapato, já que os carrapatos podem estar ocultos parcial ou totalmente abaixo do pêlo do animal. Além disso, as imagens foram coletadas no mesmo local, no mesmo turno, nas mesmas instalações físicas e com animais de um mesmo produtor, o que conduziu a uma baixa variabilidade das imagens obtidas. A baixa variabilidade, que é uma característica pouco desejável a dados utilizados para algoritmos de aprendizado de máquina, provavelmente levará à uma redução da generalidade do modelo, reduzindo sua acurácia em condições diferentes daquelas do momento da coleta das imagens.

Além dos testes realizados após o processo de treinamento, com as imagens de bovinos da mesma raça Brangus, o modelo também foi testado em outras duas condições diferentes. O primeiro teste foi realizado em vídeo para reconhecer carrapatos em um cachorro de pelagem escura. O segundo teste foi realizado em vídeo com um bovino de outra raça e com pelagem mais clara. Esses testes foram realizados com a finalidade de mostrar que, apesar de ter sido testado com outra raça e outros animais, o modelo foi capaz de detectar carrapatos em outro animal e em outra raça.

5.1 Trabalhos Futuros

Após os testes que mostram a viabilidade do uso da abordagem aqui proposta, a primeira atividade a ser executada é ampliação da quantidade de amostras da base de treinamento. Idealmente, esta ampliação deveria conter bovinos de outras raças, diferentes idades de animais e em diferentes ambientes de manejo. A partir do treinamento em uma base de imagens com maior variabilidade, é esperado que o modelo obtenha um aprendizado mais amplo sobre todas aquelas características que correspondem ou não a um carrapato, ampliando sua acurácia e sua capacidade de generalização.

Resultados aqui obtidos também sugerem que é possível treinar a mesma arquitetura para tratar problemas similares, tais como detecção de mosca do chifre e detecção de feridas e mífase (infestação larval).

Por fim, espera-se que modelos de inteligência artificial sejam cada vez mais utilizados para contribuir na solução de problemas na área da pecuária, dado seu potencial de gerar grandes contribuições para o bem-estar dos animais e, consequentemente, para a economia da região.

REFERÊNCIAS

- AGGARWAL, C. C. (Ed.). **Data Classification Algorithms and Applications**. 1st. ed. New York: CRC Press, 2015. (Chapman & Hall/CRC).
- AGRONET. La inteligencia artificial al servicio de la agricultura. 2019.
- ALA'RAJ, M.; MAJDALAWIEH, M. A hybrid approach for counting templates in images. In: **Proceedings of the 2020 2nd International Conference on Image, Video and Signal Processing**. New York, NY, USA: Association for Computing Machinery, 2020. ISBN 9781450376952.
- ALOM, Z. et al. Microscopic nuclei classification, segmentation, and detection with improved deep convolutional neural networks (DCNN). **Diagnostic Pathology**, v. 17, n. 38, 2022.
- ALVARES, D. Modelos de regressão aplicados em pesquisas em informática na educação. In: JAQUES, P. A. et al. (Ed.). **Metodologia de Pesquisa Científica em Informática na Educação: Abordagem Quantitativa**. Porto Alegre: SBC, 2020. chp. 11. Available from Internet: <<https://metodologia.ceie-br.org/livro-2/>>.
- AMMAR, A.; KOUBAA, A.; BENJDIRA, B. Deep-learning-based automated palm tree counting and geolocation in large farms from aerial geotagged images. **Agronomy**, v. 11, 2021.
- BARBEDO, J. G. A. A review on the main challenges in automatic plant disease identification based on visible range images. **Biosystems Engineering**, v. 144, 2016.
- BARBEDO, J. G. A. et al. The use of infrared images to detect ticks in cattle and proposal of an algorithm for quantifying the infestation. **Veterinary Parasitology**, v. 235, p. 106–112, 2017. ISSN 0304-4017. Available from Internet: <<https://www.sciencedirect.com/science/article/pii/S0304401717300304>>.
- BARBOSA, G. et al. Segurança em redes 5G: Oportunidades e desafios em detecção de anomalias e previsão de tráfego baseadas em aprendizado de máquina. In: **XXI Simpósio Brasileiro de Segurança da Informação e de Sistemas Computacionais (SBSeg 2021)**. Belém, PA: SBC, 2021. p. 145–189. ISBN 9786587003658.
- BJERGE, K. et al. An automated light trap to monitor moths (lepidoptera) using computer vision-based tracking and deep learning. **Sensors**, v. 21, 2021.
- BRADLEY, A. P. The use of the area under the roc curve in the evaluation of machine learning algorithms. **Pattern Recognition**, v. 30, n. 7, 1997.
- CAMPOVERDE, A.; BARROS, G. Detection and classification of urban actors through tensorflow with an android device. In: C, E. F. et al. (Ed.). **Information and Communication Technologies of Ecuador (TIC.EC)**. Cham: Springer International Publishing, 2020. p. 167–181. ISBN 978-3-030-35740-5.
- CAO, L. et al. The field wheat count based on the efficientdet algorithm. In: **2020 IEEE 3rd International Conference on Information Systems and Computer Aided Education (ICISCAE)**. Dalian, China: IEEE, 2020. p. 557–561.

CECHINEL, C.; CAMARGO, S. da S. Mineração de dados educacionais: avaliação e interpretação de modelos de classificação. In: JAQUES, P. A. et al. (Ed.).

Metodologia de Pesquisa Científica em Informática na Educação: Abordagem Quantitativa. Porto Alegre: SBC, 2020. chp. 12. Available from Internet: <<https://metodologia.ceie-br.org/livro-2/>>.

CHEN, C.-H.; KUNG, H.-Y.; HWANG, F.-J. Deep learning techniques for agronomy applications. **Agronomy**, v. 9, 2019.

CHEN, G.; SHANG, Y. Transformer for tree counting in aerial images. **Remote Sensing**, v. 14, 2022.

CHEN, Y. et al. Strawberry yield prediction based on a deep neural network using high-resolution aerial orthoimages. **Remote Sensing**, v. 11, 2019.

CIPOLINI, M.; MANGOLD, A.; JACOBO, R. **Actualización: Tristeza Bovina, Diagnóstico Clínico, Tratamiento**. Buenos Aires, AR, 2004. Available from Internet: <https://www.produccion-animal.com.ar/sanidad_intoxicaciones_metabolicos/parasitarias/Bovinos_garrapatas_tristeza/30-tristeza_bovina.pdf>.

CONCHA, N. L. S. P. U. R. Técnicas de segmentación en procesamiento digital de imágenes. **Revista de Ingeniería de Sistemas e Informática** v. 6, n. 2, p. 8, 2009. Available from Internet: <https://sisbib.unmsm.edu.pe/BibVirtual/Publicaciones/risi/2009_n2/v6n2/a02v6n2.pdf>.

CORNUÉJOLS, A.; MURENA, P.-A.; OLIVIER, R. Transfer learning by learning projections from target to source. In: BERTHOLD, M. R.; FEELDERS, A.; KREMPL, G. (Ed.). **Advances in Intelligent Data Analysis XVIII**. Cham: Springer International Publishing, 2020. p. 119–131. ISBN 978-3-030-44584-3.

CORTIVO, P. D. et al. Use of thermographic images to detect external parasite load in cattle. **Computers and Electronics in Agriculture**, v. 127, 2016.

CUORE, U. et al. Tick generational treatment. implementation of a methodology to eradicate *Rhipicephalus (Boophilus) microplus* tick resistant to macrocyclic lactones in a population management. **Veterinaria (Montevideo)**, v. 51, n. 198, p. 14–25, 2015. Available from Internet: <http://www.scielo.edu.uy/scielo.php?script=sci_arttext&pid=S1688-48092015000200002>.

CUORE, U.; SOLARI, M. Poblaciones multirresistentes de garrapatas *Rhipicephalus (Boophilus) microplus* en uruguay. **Veterinaria (Montevideo)**, v. 50, n. 193, p. 1–13, 2014.

DENG, R. et al. Automated counting grains on the rice panicle based on deep learning method. **Sensors**, v. 21, 2021.

Departamento de Control de Productos Veterinarios. **Tratamiento Generacional de la Garrapata**. Montevideo, Uruguay, 2020. 4 p.

DLUŽNEVSKIJ, D.; STEFANOVIČ, P.; RAMANAUSKAITĖ, S. Investigation of YOLOv5 efficiency in iphone supported systems. **Baltic Journal of Modern Computing**, v. 9, n. 3, p. 333–344, 2021.

DOERING, E. et al. Automatic detection and counting of malaria parasite-infected blood cells. In: SU, R.; LIU, H. (Ed.). **Medical Imaging and Computer-Aided Diagnosis**. Singapore: Springer, 2020. p. 145–157. ISBN 978-981-15-5199-4.

EVANGELINE, I. K. et al. Automatic detection and counting of lymphocytes from immunohistochemistry cancer images using deep learning. **Journal of Medical and Biological Engineering**, v. 40, p. 735–747, 2020.

EZANNO, P. et al. Research perspectives on animal health in the era of artificial intelligence. **Veterinary Research**, v. 52, n. 40, 2021.

FARINATTI, L. A. La historia agraria en el sur de brasil: un panorama sobre los últimos avances historiográficos. **Boletín del Instituto de Historia Argentina y Americana Dr. Emilio Ravignani**, n. 48, dic. 2017. Available from Internet: <<http://revistascientificas.filo.uba.ar/index.php/boletin/article/view/6548>>.

FRANCO, E. F.; RAMOS, R. J. Machine learning and deep learning in biotechnology: applications, impacts, and challenges. **Ciencia, Ambiente y Clima**, v. 2, n. 2, 2019. ISSN 2636-2317.

FUKUDA, M.; OKUNO, T.; YUKI, S. Central object segmentation by deep learning to continuously monitor fruit growth through RGB images. **Sensors**, v. 21, n. 21, 2021.

FURLONG, J.; MARTINS, J. R. S. **Resistencia dos carrapatos aos carrapaticidas**. Juiz de Fora, MG, 2000. 25 p. Available from Internet: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/81902/1/Resistencia-dos-carrapatos.pdf>>.

GARCÍA, I. G. **Descripción Morfológica de la embriogénesis de la garrapata del ganado *Rhipicephalus (Boophilus) microplus***. Dissertation (Master) — UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO, August 2014.

GKOUZIONIS, I. et al. A YOLOv5-based network for the detection of a diffuse reflectance spectroscopy probe to aid surgical guidance in gastrointestinal cancer surgery. **International Journal of Computer Assisted Radiology and Surgery**, 06 2023.

GOCHOO, M. et al. A systematic deep learning based overhead tracking and counting system using RGB-D remote cameras. **Applied Sciences**, v. 11, n. 12, 2021.

GONZALEZ, R. C. **Tratamiento digital de imágenes**. 1. ed. New York: Addison-Wesley, 1996.

GOUIAA, R.; AKHLOUFI, M. A.; SHAHBAZI, M. Advances in convolution neural networks based crowd counting and density estimation. **Big Data and Cognitive Computing**, v. 5, n. 4, 2021.

GRISI, L. Reassessment of the potential economic impact of cattle parasites in brazil. **Revista Brasileira de Parasitologia Veterinária**, v. 23, 2014.

HAIYAN, J. et al. Detecting and counting method for small-sized and occluded rice panicles based on in-field images. **Transactions of the Chinese Society of Agricultural Machinery**, v. 51, 2020.

- HASSAN, S. A. et al. Recent developments in detection of central serous retinopathy through imaging and artificial intelligence techniques—a review. **IEEE Access**, v. 9, p. 168731–168748, 2021.
- HIGA, L. de O. S. et al. Acaricide resistance status of the *Rhipicephalus microplus* in brazil: A literature overview. **Medicinal chemistry**, v. 5, n. 7, p. 326–333, 2015.
- HINTON, G. E.; OSINDERO, S.; TEH, Y.-W. A Fast Learning Algorithm for Deep Belief Nets. **Neural Computation**, v. 18, n. 7, p. 1527–1554, 07 2006. ISSN 0899-7667. Available from Internet: <<https://doi.org/10.1162/neco.2006.18.7.1527>>.
- HONG, S.-J. et al. Automatic pest counting from pheromone trap images using deep learning object detectors for matusuccus thunbergianae monitoring. **Insects**, v. 12, n. 4, 2021.
- HOSSEINI, S. M. H.; CHEN, H.; JABLONSKI, M. M. Automatic detection and counting of retina cell nuclei using deep learning. In: KROL, A.; GIMI, B. S. (Ed.). **Medical Imaging 2020: Biomedical Applications in Molecular, Structural, and Functional Imaging**. SPIE, 2020. v. 11317, p. 113172I. Available from Internet: <<https://doi.org/10.1117/12.2567454>>.
- HOSSEINY, B.; RASTIVEIS, H.; HOMAYOUNI, S. An automated framework for plant detection based on deep simulated learning from drone imagery. **Remote Sensing**, v. 12, n. 21, 2020.
- Huawei Technologies Co. Huawei cloud enterprise intelligence application platform. In: **Artificial Intelligence Technology**. Singapore: Springer Nature, 2023. p. 239–296. ISBN 978-981-19-2879-6. Available from Internet: <https://doi.org/10.1007/978-981-19-2879-6_8>.
- INIK, Ö.; ÜLKER, E. Optimization of deep learning based segmentation method. **Soft Computing**, v. 26, p. 3329–3344, 2022.
- JIA, C. et al. Improving the performance of distributed tensorflow with RDMA. **International Journal of Parallel Programming**, v. 46, 2018.
- KIM, J. et al. Embeddedpigcount: Pig counting with video object detection and tracking on an embedded board. **Sensors**, v. 22, n. 7, 2022.
- KLAFKE, G. et al. La multiresistencia a los acaricidas y el control integral de garrapatas en brasil (multiresistance to acaricides and the integrated control of cattle ticks in brazil). In: . [S.l.: s.n.], 2013.
- KUHN, M.; JOHNSON, K. **Applied Predictive Modeling**. 1. ed. [S.l.]: Springer New York, 2013. ISBN 978-1-4614-6849-3.
- LAVITT, F. et al. Deep learning and transfer learning for automatic cell counting in microscope images of human cancer cell lines. **Applied Sciences**, v. 11, n. 11, 2021.
- LEÓN, A. A. P. de et al. One health approach to identify research needs in bovine and human babesioses: workshop report. **Parasites & Vectors**, v. 3, n. 36, 2010.

LIU, S. et al. Path aggregation network for instance segmentation. In: **2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition**. Salt Lake City, UT, USA: IEEE, 2018. p. 8759–8768.

LUPPICHINI, M.; BINI, M.; GIANNECCHINI, R. Cleverriver: an open source and free google colab toolkit for deep-learning river-flow models. **Earth Science Informatics**, v. 16, n. 1, 2023. ISSN 1865-0481.

MALLOY, B. A.; POWER, J. F. An empirical analysis of the transition from python 2 to python 3. **Empirical Software Engineering**, v. 24, n. 5, 2019.

MANASWI, N. K. **Deep Learning with Applications Using Python**. [S.l.]: Apress, 2018.

MANASWI, N. K. **Deep Learning with Applications Using Python : Chatbots and Face, Object, and Speech Recognition With TensorFlow and Keras**. Berkeley, CA: Apress, 2018. ISBN 978-1-4842-3516-4.

MARCELO, J. G.; ILAO, J. P.; CORDEL, M. O. Improving vision-based detection of fruits in a camouflaged environment with deep neural networks. In: BILLINGSLEY, J.; BRETT, P. (Ed.). **Mechatronics and Machine Vision in Practice 4**. Cham: Springer International Publishing, 2021. p. 61–69. Available from Internet: <https://doi.org/10.1007/978-3-030-43703-9_5>.

MARROQUIN, J. L. Computational vision: A probabilistic view of the multi-module paradigm. In: RUDOMIN, P. et al. (Ed.). **Neuroscience: From Neural Networks to Artificial Intelligence**. Berlin, Heidelberg: Springer Berlin Heidelberg, 1993. p. 252–266. ISBN 978-3-642-78102-5.

MEKHALFI, M. L. et al. Detecting crop circles in google earth images with mask R-CNN and YOLOv3. **Applied Sciences**, v. 11, n. 5, 2021.

MU, Y. et al. Intact detection of highly occluded immature tomatoes on plants using deep learning techniques. **Sensors**, v. 20, n. 10, 2020.

NORVIG, S. R. P. **Artificial Intelligence: A Modern Approach**. 3. ed. Upper Saddle River, New Jersey: Person Education, 2002.

OKUNEV, A. G. et al. Nanoparticle recognition on scanning probe microscopy images using computer vision and deep learning. **Nanomaterials**, v. 10, n. 7, 2020.

OMIDI, A. et al. An embedded deep learning-based package for traffic law enforcement. In: **2021 IEEE/CVF International Conference on Computer Vision Workshops (ICCVW)**. Montreal, CA: IEEE, 2021. p. 262–271.

PAYTON, L. et al. Maximum entropy learning with deep belief networks. **Entropy**, v. 18, n. 7, 2016.

PEÑA, A. E. et al. Phylogeographic analysis reveals association of tick-borne pathogen, *Anaplasma marginale*, msp1a sequences with ecological traits affecting tick vector performance. **BMC Biology**, v. 7, n. 57, 2009. ISSN 1741-7007.

PIPANO, E.; HADANI, A. Control of bovine babesiosis. In: RISTIC, M.; AMBROISE-THOMAS, P.; KREIER, J. (Ed.). **Malaria and Babesiosis: Research findings and control measures**. Dordrecht: Springer Netherlands, 1984. p. 263–303. ISBN 978-94-009-6042-8.

PROKOPEV, D. I. **Resistance of malaria parasites to drugs : report of a WHO scientific group**. Michigan, 1965. (World Health Organization technical report series, 296).

QUIROZ, R. H. Parasitología y enfermedades parasitarias de animales domésticos. In: . Mexico: Editorial Limusa S.A. De C.V., 1990.

RAHNEMOONFAR, M. et al. Discountnet: Discriminating and counting network for real-time counting and localization of sparse objects in high-resolution uav imagery. **Remote Sensing**, v. 11, n. 9, 2019.

RODRÍGUEZ-VIVAS, R. I. et al. Control integrado de garrapatas en la ganadería bovina. **Ecosistemas y recursos agropecuarios**, v. 1, n. 3, 2014.

ROMERO, H. Q. et al. **Epidemiología de Enfermedades Parasitarias en Animales Domésticos**. 1. ed. Mérida, Yucatán, México: VIII Congreso Nacional de Parasitología Veterinaria, 2011.

RUPARELIA, S.; JETHVA, M.; GAJJAR, R. Real-time tomato detection, classification, and counting system using deep learning and embedded systems. In: THAKKAR, F. et al. (Ed.). **Proceedings of the International e-Conference on Intelligent Systems and Signal Processing**. Singapore: Springer Singapore, 2022. p. 511–522. ISBN 978-981-16-2123-9.

SANGHANI, R. M.; DOUKKY, R. Fully automated analysis of perfusion data: The rise of the machines. **Journal of Nuclear Cardiology**, v. 25, n. 4, 2018.

SANTOS, R. L. dos et al. A low-cost bidirectional people counter device for assisting social distancing monitoring for covid-19. **Journal of Control, Automation and Electrical Systems**, v. 33, p. 1148–1160, 2022.

SEETALA, K.; BIRDSOING, W.; REDDY, Y. B. Image classification using tensorflow. In: LATIFI, S. (Ed.). **16th International Conference on Information Technology-New Generations (ITNG 2019)**. Cham: Springer International Publishing, 2019. p. 485–488. ISBN 978-3-030-14070-0.

SILVA, J. **Um módulo inteligente baseado em aprendizado de máquina para treinamento de estudantes de medicina no DocTraining**. Thesis (PhD) — Universidade Federal Rural do Semi-Árido, Mossoró-RN, 03 2020.

SMYTH, D. J. H. H. M. P. **Principles of Data Mining**. Cambridge, USA: MIT Press, 2001. ISBN 9780262082907.

SOULSBY, E. J. L. **Parasitología Y Enfermedades Parasitarias En Los Animales Domésticos**. 7. ed. Mexico D.F: Nueva Editorial Interamericana, 1987. 823 p. Available from Internet: <<https://books.google.com.co/books?id=O6MYnQEACAAJ>>.

TEIXEIRA, J. C.; HESPANHOL, A. N. A trajetória da pecuária bovina brasileira. **Caderno Prudentino de Geografia**, v. 1, n. 36, 2014.

TESSEMA, A. W. et al. Quantitative analysis of blood cells from microscopic images using convolutional neural network. **Medical AND Biological Engineering AND Computing**, v. 59, n. 1, 2021.

TETILA, E. C. et al. A deep-learning approach for automatic counting of soybean insect pests. **IEEE Geoscience and Remote Sensing Letters**, v. 17, n. 10, p. 1837 – 1841, 2020.

The Center for Food Security & Public Health. *Rhipicephalus (Boophilus) microplus - Garrapata del ganado del sur, garrapata del ganado bovino*. Iowa, USA, 2007. Available from Internet: <https://www.cfsph.iastate.edu/Factsheets/es/boophilus_microplus-es.pdf>.

TOAL, R. et al. **Programming Language Explorations**. 1. ed. Los Angeles: CRC Press, 2016. 362 p.

TU, S. et al. Passion fruit detection and counting based on multiple scale faster R-CNN using RGB-D images. **Precision Agriculture**, v. 21, n. 5, 2020.

TUGGLE, C. K. et al. The agricultural genome to phenome initiative (ag2pi): creating a shared vision across crop and livestock research communities. **Genome Biology**, v. 23, n. 3, 2022.

VALENTE, J. et al. Automated crop plant counting from very high-resolution aerial imagery. **Precision Agriculture**, v. 21, 2020.

WANG, C. et al. CSPNet: A new backbone that can enhance learning capability of CNN. In: **2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)**. Los Alamitos, CA, USA: IEEE Computer Society, 2020. p. 1571–1580. Available from Internet: <<https://doi.ieeecomputersociety.org/10.1109/CVPRW50498.2020.00203>>.

WANG, S. et al. Automatic counting system of red blood cells based on fourier ptychographic microscopy. In: LIANG, Q. et al. (Ed.). **Communications, Signal Processing, and Systems**. Singapore: Springer Singapore, 2021. v. 654, n. 1, p. 891–898. ISBN 978-981-15-8411-4.

WANG, X. et al. Bone marrow cell counting method based on fourier ptychographic microscopy and convolutional neural network. In: LIANG, Q. et al. (Ed.). **Communications, Signal Processing, and Systems**. Singapore: Springer Singapore, 2021. v. 654, n. 1, p. 687–693. ISBN 978-981-15-8411-4.

WEI, W. et al. Automatic counting of railway tools based on deep learning. In: XIANG, Y.; LIU, Z.; LI, J. (Ed.). **Security and Privacy in Social Networks and Big Data**. Singapore: Springer Singapore, 2020. p. 355–368. ISBN 978-981-15-9031-3.

WEITZMAN, J. B. Automated analysis of tissue microarrays. **Genome Biology**, v. 3, n. spotlight-20021023-01, 2002.

WHARTON, R.; UTECH, K. The relation between engorgement and dropping of *Boophilus microplus* (canestrini) (ixodidae) to the assessmet of tick numbers on cattle. **Australian Journal of Entomology**, v. 9, n. 3, p. 171–182, 03 2007.

WU, H. et al. Vision based real-time high-accuracy automatic counting with applications for smart pharmacy. In: . [S.l.: s.n.], 2021. v. 40.

WU, J. et al. Automatic counting of in situ rice seedlings from uav images based on a deep fully convolutional neural network. **Remote Sensing**, v. 11, 2019.

XIA, X. et al. Culling double counting in sequence images for fruit yield estimation. **Agronomy**, v. 12, n. 2, 2022.

XIE, Y. et al. Optimal distributed parallel algorithms for deep learning framework tensorflow. **Applied Intelligence**, v. 52, p. 3880–3900, 2021.

YAN, M. et al. Background augmentation generative adversarial networks (bagans): Effective data generation based on gan-augmented 3d synthesizing. **Symmetry**, v. 10, n. 12, p. 734, 12 2018.

YANG, L. et al. Computer vision models in intelligent aquaculture with emphasis on fish detection and behavior analysis: A review. **Archives of Computational Methods in Engineering**, v. 28, 2021.

YE, N. **The Handbook of Data Mining**. 1. ed. Boca Raton: CRC Press, 2003. ISBN 9780805855630.

YIWEN, Z. et al. Prediction and counting of field wheat based on lc-dcvgg. **ICMAI 2020: Proceedings of the 2020 5th International Conference on Mathematics and Artificial Intelligence**, v. 5, 2020.

YUVARAJ, N. et al. 15 - analysis on the prediction of central line-associated bloodstream infections (clabsi) using deep neural network classification. In: VERMA, J. K.; PAUL, S.; JOHRI, P. (Ed.). **Computational Intelligence and Its Applications in Healthcare**. Academic Press, 2020. p. 229–244. ISBN 978-0-12-820604-1. Available from Internet: <<https://www.sciencedirect.com/science/article/pii/B9780128206041000169>>.

ZHANG, J. et al. A comprehensive review of image analysis methods for microorganism counting: from classical image processing to deep learning approaches. **Artificial Intelligence Review**, v. 55, n. 4, 2021.

ZHOU, Y. et al. Erythroidcounter: an automatic pipeline for erythroid cell detection, identification and counting based on deep learning. **Multimedia Tools and Applications**, v. 81, n. 18, p. 25541–25556, 2022.