



INSTITUTO FEDERAL GOIANO
CAMPUS URUTAÍ
NÚCLEO DE INFORMÁTICA
CURSO DE SISTEMAS DE INFORMAÇÃO

HIANN ALEXANDER MENDES DE OLIVEIRA

VISÃO COMPUTACIONAL APLICADA À DETECÇÃO DE ANAPLASMA PLATYS EM PLAQUETAS

Urutaí, 3 de março de 2026

INSTITUTO FEDERAL GOIANO
NÚCLEO DE INFORMÁTICA
SISTEMAS DE INFORMAÇÃO

HIANN ALEXANDER MENDES DE OLIVEIRA

**VISÃO COMPUTACIONAL APLICADA À
DETECÇÃO DE ANAPLASMA PLATYS EM
PLAQUETAS**

Monografia apresentada ao Núcleo de Informática, curso de Sistemas de Informação, do Instituto Federal Goiano, como parte das exigências para obtenção do título de Bacharel em Sistemas de Informação.

Orientador(a):
Gabriel da Silva Vieira

Co-orientador(a):
Saulo Humberto de Ávila Filho

Urutaí, 3 de março de 2026

**Ficha de identificação da obra elaborada pelo autor, através do
Programa de Geração Automática do Sistema Integrado de Bibliotecas do IF Goiano - SIBi**

O48v Mendes de Oliveira, Hiann Alexander
 VISÃO COMPUTACIONAL APLICADA À DETECÇÃO DE
 ANAPLASMA PLATYS EM PLAQUETAS / Hiann Alexander
 Mendes de Oliveira. Pires do Rio 2025.

 58f. il.

 Orientador: Prof. Dr. Gabriel da Silva Vieira.
 Coorientador: Prof. Dr. Saulo Humberto de Ávila Filho.
 Monografia (Bacharel) - Instituto Federal Goiano - Campus
 Urutaí, curso de 0120201 - Bacharelado em Sistemas de
 Informação - Urutaí (Campus Urutaí).
 1. Visão computacional. 2. Processamento de imagens. 3.
 Inteligência artificial. 4. Anaplasma platys. I. Título.

TERMO DE CIÊNCIA E DE AUTORIZAÇÃO

PARA DISPONIBILIZAR PRODUÇÕES TÉCNICO-CIENTÍFICAS

NO REPOSITÓRIO INSTITUCIONAL DO IF GOIANO

Com base no disposto na Lei Federal nº 9.610, de 19 de fevereiro de 1998, AUTORIZO o Instituto Federal de Educação, Ciência e Tecnologia Goiano a disponibilizar gratuitamente o documento em formato digital no Repositório Institucional do IF Goiano (RIIF Goiano), sem ressarcimento de direitos autorais, conforme permissão assinada abaixo, para fins de leitura, download e impressão, a título de divulgação da produção técnico-científica no IF Goiano.

IDENTIFICAÇÃO DA PRODUÇÃO TÉCNICO-CIENTÍFICA

- ☐ Tese (doutorado)
☐ Dissertação (mestrado)
☐ Monografia (especialização)
☒ TCC (graduação)

- ☐ Artigo científico
☐ Capítulo de livro
☐ Livro
☐ Trabalho apresentado em evento

☐ Produto técnico e educacional - Tipo:

Nome completo do autor:

Hiann Alexander Mendes de Oliveira

Matrícula:

2020101202010103

Título do trabalho:

VISÃO COMPUTACIONAL APLICADA À DETECÇÃO DE ANAPLASMA PLATYS EM PLAQUETAS

RESTRIÇÕES DE ACESSO AO DOCUMENTO

Documento confidencial: ☒ Não ☐ Sim, justifique:

Informe a data que poderá ser disponibilizado no RIIF Goiano: 02 / 03 / 2026

O documento está sujeito a registro de patente? ☐ Sim ☒ Não

O documento pode vir a ser publicado como livro? ☐ Sim ☒ Não

DECLARAÇÃO DE DISTRIBUIÇÃO NÃO-EXCLUSIVA

O(a) referido(a) autor(a) declara:

- Que o documento é seu trabalho original, detém os direitos autorais da produção técnico-científica e não infringe os direitos de qualquer outra pessoa ou entidade;
- Que obteve autorização de quaisquer materiais inclusos no documento do qual não detém os direitos de autoria, para conceder ao Instituto Federal de Educação, Ciência e Tecnologia Goiano os direitos requeridos e que este material cujos direitos autorais são de terceiros, estão claramente identificados e reconhecidos no texto ou conteúdo do documento entregue;
- Que cumpriu quaisquer obrigações exigidas por contrato ou acordo, caso o documento entregue seja baseado em trabalho financiado ou apoiado por outra instituição que não o Instituto Federal de Educação, Ciência e Tecnologia Goiano.

Urutaí, Goiás

28 / 02 / 2026

Local

Data



Documento assinado digitalmente

HIANN ALEXANDER MENDES DE OLIVEIRA

Data: 28/02/2026 18:47:56-0300

Verifique em <https://validar.iti.gov.br>

Assinatura do autor e/ou detentor dos direitos autorais

Ciente e de acordo:

Assinatura do(a) orientador(a)



Documento assinado digitalmente

GABRIEL DA SILVA VIEIRA

Data: 02/03/2026 17:54:27-0300

Verifique em <https://validar.iti.gov.br>



SERVIÇO PÚBLICO FEDERAL
MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA GOIANO

Ata nº 28/2025 - CCBSI-URT/GE-UR/DE-UR/CMPURT/IFGOIANO

CURSO SUPERIOR DE SISTEMAS DE INFORMAÇÃO
ATA DE APRESENTAÇÃO DE TRABALHO DE CURSO

Aos onze dias do mês de dezembro de dois mil e vinte e cinco, reuniram-se os professores: Gabriel da Silva Vieira, Cristiane de Fátima dos Santos Cardoso, Nattane Luiza da Costa, e o médico veterinário Saulo Humberto de Ávila Filho nas dependências do Instituto Federal Goiano - Campus Urutaí, para avaliar o Trabalho de Curso do acadêmico: **Hiann Alexander Mendes de Oliveira**, como requisito necessário para a conclusão do Curso Superior de Sistemas de Informação desta Instituição. O presente TC tem como título: **VISÃO COMPUTACIONAL APLICADA À DETECÇÃO DE ANAPLASMA PLATYS EM PLAQUETAS**, foi orientado por Gabriel da Silva Vieira e coorientado por Saulo Humberto de Ávila Filho.

Após análise, foram dadas as seguintes notas:

Professores	Aluno / Notas
	Hiann Alexander Mendes De Oliveira
1. Gabriel da Silva Vieira	8.0
2. Saulo Humberto de Ávila Filho	8.0
3. Cristiane de Fátima dos Santos Cardoso	7.0
4. Nattane Luiza da Costa	6.3
MÉDIA FINAL:	7.3

OBSERVAÇÕES:

Por ser verdade firmamos a presente:

(Assinado Eletronicamente)

Gabriel da Silva Vieira

Orientador(a)

(Assinado Eletronicamente)

Saulo Humberto de Ávila Filho

Coorientador(a)

(Assinado Eletronicamente)

Cristiane de Fátima dos Santos Cardoso

Membro

(Assinado Eletronicamente)

Nattane Luiza da Costa

Membro

Documento assinado eletronicamente por:

- **Gabriel da Silva Vieira, PROFESSOR ENS BASICO TECN TECNOLOGICO** , em 12/12/2025 19:35:14.
- **Saulo Humberto de Avila Filho, MEDICO VETERINARIO** , em 12/12/2025 19:40:13.
- **Nattane Luiza da Costa, PROFESSOR ENS BASICO TECN TECNOLOGICO** , em 13/12/2025 08:27:45.
- **Cristiane de Fatima dos Santos Cardoso, PROFESSOR ENS BASICO TECN TECNOLOGICO** , em 18/12/2025 14:15:05.

Este documento foi emitido pelo SUAP em 10/12/2025. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifgoiano.edu.br/autenticar-documento/> e forneça os dados abaixo:

Código Verificador: 772908

Código de Autenticação: 6a3470aec2



INSTITUTO FEDERAL GOIANO

Campus Urutaí

Rodovia Geraldo Silva Nascimento, Km 2.5, SN, Zona Rural, URUTAÍ / GO, CEP 75790-000

(64) 3465-1900



SERVIÇO PÚBLICO FEDERAL
MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA GOIANO

Documentos 18/2025 - CCBSI-URT/GE-UR/DE-UR/CMPURT/IFGOIANO

HIANN ALEXANDER MENDES DE OLIVEIRA

VISÃO COMPUTACIONAL APLICADA À DETECÇÃO DE ANAPLASMA PLATYS EM PLAQUETAS

Monografia, defendida por Hiann Alexander Mendes de Oliveira, apresentada ao Instituto Federal de Educação, Ciência e Tecnologia Goiano, como parte das exigências para a obtenção do título de Bacharel em Sistemas de Informação, aprovada pela banca examinadora.

COMISSÃO EXAMINADORA

(Assinado Eletronicamente)

Prof. Dr. Gabriel da Silva Vieira

Orientador

(Assinado Eletronicamente)

Dr. Saulo Humberto de Ávila Filho

Coorientador

(Assinado Eletronicamente)

Profa. Dra. Cristiane de Fátima dos Santos Cardoso

Avaliadora

(Assinado Eletronicamente)

Profa. Dra. Nattane Luiza da Costa

Urutaí (GO), 11 de dezembro de 2025.

Documento assinado eletronicamente por:

- **Gabriel da Silva Vieira, PROFESSOR ENS BASICO TECN TECNOLOGICO** , em 12/12/2025 19:38:43.
- **Saulo Humberto de Avila Filho, MEDICO VETERINARIO** , em 12/12/2025 19:41:20.
- **Cristiane de Fatima dos Santos Cardoso, PROFESSOR ENS BASICO TECN TECNOLOGICO** , em 18/12/2025 14:15:44.
- **Nattane Luiza da Costa, PROFESSOR ENS BASICO TECN TECNOLOGICO** , em 26/02/2026 12:58:42.

Este documento foi emitido pelo SUAP em 10/12/2025. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifgoiano.edu.br/autenticar-documento/> e forneça os dados abaixo:

Código Verificador: 772905

Código de Autenticação: 20fd40c634



INSTITUTO FEDERAL GOIANO

Campus Urutaí

Rodovia Geraldo Silva Nascimento, Km 2.5, SN, Zona Rural, URUTAÍ / GO, CEP 75790-000

(64) 3465-1900

AGRADECIMENTOS

Ao longo desses anos, tenho muito a agradecer. As experiências, aprendizados, frustrações, alegrias e noites mal dormidas tiveram, a meu ver, um propósito para que eu chegasse até aqui.

Primeiramente, gostaria de agradecer a Deus por me permitir chegar até aqui e concluir mais esta etapa de minha vida. Creio que cada minucioso detalhe desta jornada estava nos planos Dele e sou extremamente grato por ter tido forças para chegar a este momento.

Gostaria também de agradecer aos meus pais, Jesiane Mendes de Oliveira e Warley Ferreira de Oliveira, por todo o amor, carinho, atenção e paciência ao longo destes anos. Sei que não foi fácil. Agradeço pelas broncas quando necessárias e por me aconselharem. Esta conquista é de vocês também. Deixo aqui meu agradecimento e carinho às minhas avós, Marise José da Silva Bastos (avó materna) e Valdina Diniz Gonçalves Oliveira (avó paterna), pelas orações, abraços e carinho que sempre tiveram por mim.

Deixo aqui meu agradecimento especial à minha namorada, Any Guimarães Silva, por ser essa parceira incrível, por me incentivar sempre e por ter paciência, principalmente nesta reta final. Agradeço por toda a ajuda, seja em forma de companhia ou no apoio direto com o treinamento executado neste TCC. Sou imensamente grato. Estendo meu agradecimento aos pais dela, Maria Aparecida de Souza Guimarães e Adelson Francisco da Silva, por todo o apoio e incentivo que sempre me deram nesta reta final.

Nada disso seria possível sem o Instituto Federal Goiano - Campus Urutaí, que me acolheu nestes anos e me proporcionou uma educação de qualidade, com professores extremamente profissionais, pelos quais tenho muita admiração. Estendo meu agradecimento especial ao meu orientador, Professor Gabriel da Silva Vieira, que teve imensa paciência ao longo deste projeto, que se estendeu além do esperado. Agradeço também ao meu co-orientador, Doutor Saulo Humberto de Ávila Filho, por abraçar este projeto. Através dele, estendo meu agradecimento ao Hospital Veterinário do Campus, por ajudar de forma direta com as amostras essenciais para que o treinamento fosse realizado.

E por último, mas não menos importante, gostaria de agradecer a todos que cruzaram o meu caminho nesta jornada. Aos que seguiram seus distintos caminhos e aos que ainda permanecem próximos, creio que de alguma forma foi benéfico e que pudemos acrescentar algo na vida uns dos outros.

All good things come with time

Avenged Sevenfold,
Sunny Disposition.

O diagnóstico da anaplasmosse canina, doença causada pela **Anaplasma platys**, depende da identificação microscópica do patógeno nas plaquetas, um processo manual que é demorado, subjetivo e suscetível a erros. Este trabalho propõe um modelo de aprendizado de máquina (YOLOv8) para automatizar a detecção e classificação de plaquetas saudáveis e infectadas. Para isso, foi construído um dataset híbrido (imagens reais do Hospital Veterinário do IF Goiano – Campus Urutaí e da internet), treinado com uma divisão de 80% para treino e 20% para validação. Os resultados demonstram a viabilidade do protótipo: a análise gráfica indicou que o modelo aprendeu a identificar os padrões, mas revelou uma tendência a falsos positivos (clasificando plaquetas saudáveis como doentes). Conclui-se que a ferramenta é promissora para o diagnóstico auxiliar, mas sua precisão é limitada pelo dataset restrito. Como trabalhos futuros, recomenda-se a expansão do dataset para aprimorar o desempenho.

Palavras-chave:

Aprendizado de Máquina, Detecção de Objetos, Anaplasmosse Canina, YOLOv8, Plaquetas

ABSTRACT

The manual identification of **Anaplasma platys** in platelets, essential for diagnosing canine anaplasmosis, is a time-consuming and error-prone process. This work proposes a machine learning model (YOLOv8) to automate the detection and classification of healthy and infected platelets. For this, a hybrid dataset (real images from the HV-IF Goiano – Campus Urutaí and the internet) was built, trained with an 80% train and 20% validation split. The results demonstrate the prototype's viability: graphical analysis indicated the model learned to identify patterns but revealed a tendency for false positives (classifying healthy platelets as diseased). It is concluded that the tool is promising for auxiliary diagnosis, but its precision is limited by the restricted dataset. For future work, dataset expansion is recommended to improve performance.

Keywords: Machine Learning, Object Detection, Canine Anaplasmosis, YOLOv8, Platelets

LISTA DE FIGURAS

4.1	Fluxograma metodológico e representação visual das etapas de anotação e inferência do modelo YOLOv8.	26
5.1	Gráficos de métricas e perdas durante o treinamento do YOLOv8.	31
5.2	Matriz de confusão do conjunto de validação.	32
5.3	Detecção correta de plaquetas doentes.	34
5.4	Detecção de plaquetas saudáveis e presença de falso negativo.	35
5.5	Exemplo de detecção correta em campo denso.	36
5.6	Detecção individual correta.	37
5.7	Erro de classificação: Hemácia identificada como plaqueta.	38
5.8	Detecção correta de plaqueta doente.	39
5.9	Ocorrência simultânea de Falso Positivo e Falso Negativo.	40
5.10	Presença de Falsos Negativos e Falso Positivo na mesma amostra.	41
5.11	Detecção correta de plaquetas saudáveis.	42

LISTA DE TABELAS

3.1	Comparativo de trabalhos relacionados na detecção de hemoparasitas.	22
4.1	Distribuição das imagens do <i>dataset</i> segundo a origem.	24
4.2	Divisão do <i>dataset</i> de 44 imagens.	25
4.3	Hiperparâmetros utilizados no treinamento do YOLOv8.	27
5.1	Métricas de desempenho finais no conjunto de validação (Pico Médio).	32
5.2	Matriz de Confusão detalhada do conjunto de validação.	33

1	INTRODUÇÃO	14
1.1	Problema de Pesquisa	14
1.2	Justificativa	15
1.3	Objetivos	15
1.3.1	Objetivo Geral	15
1.3.2	Objetivos Específicos	16
1.4	Estrutura do Trabalho	16
2	A ANAPLASMOSE CANINA	17
2.1	Etiologia	17
2.2	Epidemiologia	18
2.3	Patogenia e Sinais Clínicos	18
2.4	Diagnóstico	18
2.5	Tratamento	19
3	FUNDAMENTAÇÃO TEÓRICA: VISÃO COMPUTACIONAL	20
3.1	Inteligência Artificial e Visão Computacional	20
3.2	Detecção de Objetos: A Arquitetura YOLOv8	21
3.3	Trabalhos Relacionados (Estado da Arte)	21
4	MATERIAIS E MÉTODOS	23
4.1	Ferramentas de Software	23
4.2	Construção do <i>Dataset</i>	23
4.2.1	Coleta e Origem das Imagens	24
4.2.2	Anotação e Definição de Classes	24
4.2.3	Divisão do <i>Dataset</i>	25
4.3	Configuração e Treinamento (<i>train.py</i>)	26
4.3.1	Arquivo de Configuração do <i>Dataset</i>	27
4.3.2	Hiperparâmetros de Treinamento	27
4.4	Inferência e Análise de Resultados (<i>predict_with_db.py</i>)	27
4.4.1	Processamento em Lote	27
4.4.2	Persistência de Dados	28
4.5	Métricas de Avaliação	28
4.5.1	Matriz de Confusão	28

4.5.2	Precisão Média (mAP)	29
5	RESULTADOS E DISCUSSÃO	30
5.1	Ambiente de Treinamento e Execução	30
5.2	Análise das Métricas de Desempenho	30
5.3	Análise Crítica dos Erros	32
5.4	Análise Qualitativa	34
5.5	Discussão Geral	43
5.5.1	Implicações Práticas	43
5.5.2	Limitações do Estudo	43
5.5.3	Comparação com Trabalhos Relacionados	43
6	CONCLUSÃO	44
6.1	Retomada dos Objetivos	44
6.2	Considerações Finais	44
6.3	Trabalhos Futuros	45
A	IMAGENS DO DATASET UTILIZADO	46
A.1	Imagens do Hospital Veterinário do IF Goiano – Campus Urutaí	46
A.2	Imagens provenientes de clínica veterinária privada (Goiânia)	52
A.3	Imagens obtidas de fontes públicas online	53

Imagine um inimigo invisível, microscópico, que se esconde dentro das células do sangue, causando uma doença silenciosa que pode ser fatal se não descoberta a tempo. Para quem tem um animal de estimação, a saúde dele é uma prioridade, mas muitas vezes os sinais de perigo são sutis demais para serem notados a olho nu. É neste cenário que a tecnologia entra como uma aliada poderosa: algoritmos inteligentes capazes de enxergar o que, muitas vezes, escapa até aos olhos humanos mais treinados, transformando pixels em diagnósticos que salvam vidas.

A medicina veterinária moderna enfrenta desafios constantes na busca por diagnósticos rápidos e precisos. No Brasil, as Doenças Transmitidas por Vetores (DTV), popularmente conhecidas como “doenças do carrapato”, representam uma parcela significativa dos atendimentos clínicos. Dentre estas enfermidades, a anaplasmoze canina destaca-se não apenas pela sua prevalência, mas pela complexidade de sua identificação laboratorial (OTRANTO et al., 2010).

Este trabalho propõe a integração entre a medicina veterinária e a ciência da computação para abordar um problema clássico da patologia clínica: a subjetividade e a dificuldade na detecção visual de hemoparasitas.

1.1 Problema de Pesquisa

A anaplasmoze, causada pela bactéria *Anaplasma platys*, infecta especificamente as plaquetas dos cães. O método de diagnóstico mais acessível e difundido na rotina veterinária é o esfregaço sanguíneo, onde o patologista busca identificar visualmente a presença de mórulas (inclusões bacterianas) no interior das células.

No entanto, este método apresenta limitações críticas. A identificação é um processo

manual, dependente da experiência do observador e suscetível à fadiga visual. Além disso, a parasitemia da *A. platys* é cíclica e transitória, o que significa que a quantidade de bactérias no sangue varia, tornando a detecção visual um desafio comparável a encontrar uma agulha em um palheiro. Erros de diagnóstico — tanto falsos negativos quanto falsos positivos — são riscos constantes que podem comprometer o tratamento do animal.

1.2 Justificativa

A justificativa para este estudo reside na necessidade de ferramentas que auxiliem o médico veterinário a superar as limitações da análise visual humana. A Inteligência Artificial (IA), especificamente a área de Visão Computacional, tem demonstrado capacidade notável em reconhecimento de padrões em imagens médicas.

O desenvolvimento de um sistema capaz de realizar uma triagem automatizada de lâminas não visa substituir o profissional, mas sim fornecer uma ferramenta de suporte à decisão robusta, agilizando o processo de leitura e aumentando a confiabilidade dos laudos hematológicos.

Estudos demonstram que sistemas baseados em redes neurais profundas podem atingir desempenho comparável ao de especialistas humanos em tarefas diagnósticas. Esteve et al. (ESTEVA et al., 2017) evidenciaram esse potencial ao empregar deep learning para classificação de doenças dermatológicas em nível clínico.

1.3 Objetivos

Nesta seção são apresentados os objetivos que orientam o desenvolvimento deste trabalho. Inicialmente, é definido o objetivo geral, que expressa de forma ampla a finalidade da pesquisa. Em seguida, são elencados os objetivos específicos, os quais detalham as etapas necessárias para alcançar o objetivo principal e estruturam o percurso metodológico adotado.

1.3.1 Objetivo Geral

Desenvolver e avaliar um modelo de aprendizado de máquina, utilizando a arquitetura YOLOv8, capaz de detectar e classificar plaquetas saudáveis e infectadas por *Anaplasma platys* em imagens microscópicas.

1.3.2 Objetivos Específicos

- Realizar uma revisão bibliográfica aprofundada sobre a patogenia da anaplasmosse e métodos de diagnóstico;
- Construir um *dataset* híbrido de imagens microscópicas de plaquetas;
- Treinar e validar o modelo YOLOv8 para a tarefa de detecção de objetos;
- Avaliar o desempenho do modelo através de métricas como mAP e Matriz de Confusão.

1.4 Estrutura do Trabalho

O trabalho está organizado em seis capítulos e uma apêndice. O Capítulo 1 apresenta a introdução ao tema. O Capítulo 2 aprofunda-se ainda mais na explicação sobre a anaplasmosse canina. O Capítulo 3 descreve a metodologia computacional aplicada. O Capítulo 4 descreve detalhadamente os materiais e os métodos que foram utilizados. O Capítulo 5 apresenta os resultados do treinamento do modelo. O Capítulo 6 traz as conclusões e perspectivas futuras, e, por fim, temos a Apêndice A que apresenta integralmente as imagens do *dataset*.

CAPÍTULO 2

A ANAPLASMOSE CANINA

Este capítulo apresenta uma fundamentação teórica detalhada sobre a anaplasmoze canina, abordando aspectos essenciais como etiologia, epidemiologia, patogenia, métodos diagnósticos e tratamento. O objetivo é contextualizar a importância clínica da doença e detalhar as limitações dos métodos diagnósticos atuais, baseando-se em literatura recente e clássica da medicina veterinária.

2.1 Etiologia

Revisões recentes da literatura científica apontam para o aumento da relevância das infecções transmitidas por carrapatos em cães, destacando a necessidade de abordagens diagnósticas mais eficientes (ScienceDirect AI, 2024b; ScienceDirect AI, 2024a).

A anaplasmoze canina tem sido reconhecida como uma enfermidade emergente de importância não apenas veterinária, mas também em saúde pública, devido ao seu potencial zoonótico e ampla distribuição geográfica. Estudos recentes destacam a necessidade de estratégias diagnósticas mais eficientes para o controle da trombocitopenia infecciosa cíclica canina (ATIF et al., 2021).

Embora a *Anaplasma phagocytophilum* seja uma espécie relevante (infectando neutrófilos), o foco deste estudo recai sobre a *Anaplasma platys*. Descoberta na década de 1970, a *A. platys* é o agente etiológico da Trombocitopenia Cíclica Infecciosa Canina (TCIC). Sua característica biológica fundamental para este trabalho é o tropismo exclusivo pelas plaquetas sanguíneas (trombócitos), onde se multiplica formando inclusões basofílicas densas denominadas mórulas (NEER et al., 2002; LITTLE, 2010).

2.2 Epidemiologia

A doença possui distribuição mundial, ocorrendo preferencialmente em regiões tropicais e subtropicais devido às condições climáticas favoráveis à proliferação dos vetores, ela tem sido relatada em diferentes regiões do mundo, com casos documentados na Europa, América e Ásia, evidenciando sua ampla distribuição geográfica (DYACHENKO et al., 2012). O principal vetor da *A. platys* é o carrapato marrom do cão, *Rhipicephalus sanguineus* (SAINZ et al., 2015).

No Brasil, especialmente em regiões como o semiárido, observa-se uma elevada prevalência da infecção. Um estudo recente de Silva et al. (2025) destacou a alta frequência de *A. platys* e sua comum coinfeção com a *Ehrlichia canis*, o que agrava o quadro clínico dos animais. A anaplasmosose apresenta taxas significativas de morbidade e impacto econômico elevado devido aos custos com diagnósticos e tratamentos prolongados (MARTINESCU et al., 2024).

Além disso, a doença possui relevância em Saúde Única. Embora o cão seja o reservatório primário, evidências sugerem o potencial zoonótico de espécies do gênero *Anaplasma*, reforçando a necessidade de vigilância (ACOSTA-ESPAÑA et al., 2025).

2.3 Patogenia e Sinais Clínicos

A patogenia da infecção por *A. platys* é marcada pela trombocitopenia cíclica. A bactéria invade os trombócitos, replica-se e causa a lise plaquetária ou sua destruição imunomediada, resultando em quedas periódicas na contagem de plaquetas a cada 7 a 14 dias (NEER et al., 2002).

Os sinais clínicos variam:

- **Sinais Brandos:** Assintomáticos ou com febre intermitente, letargia e anorexia leve.
- **Sinais Graves:** Em infecções agudas, observam-se perda de peso, linfadenomegalia, uveíte e diáteses hemorrágicas (petéquias, equimoses, epistaxe) (LITTLE, 2010; SAINZ et al., 2015).

2.4 Diagnóstico

O diagnóstico baseia-se na associação entre anamnese, sinais clínicos e exames laboratoriais. As principais ferramentas incluem:

- **Sorologia (RIFI/ELISA):** Útil para triagem, mas pode apresentar falsos negativos em fases iniciais (janela imunológica) ou falsos positivos por cicatriz sorológica.
- **Molecular (PCR):** Alta sensibilidade e especificidade, detectando o DNA da bactéria. Contudo, seu alto custo limita o uso rotineiro (SILVA et al., 2025).
- **Parasitológico Direto (Padrão-Ouro):** Consiste na visualização das mórulas no interior das plaquetas em esfregaços sanguíneos (Giemsa/Panótico).

Apesar de ser o padrão-ouro visual, o método parasitológico possui limitações graves: a parasitemia é cíclica e transitória, gerando falsos negativos nos intervalos entre picos de infecção. Além disso, a leitura é subjetiva e depende da experiência do patologista para diferenciar mórulas de artefatos (MARTINESCU et al., 2024).

2.5 Tratamento

O tratamento baseia-se na antibioticoterapia com tetraciclina, sendo a **doxiciclina** o fármaco de escolha. O protocolo é prolongado (28 dias ou mais) para garantir a eliminação do agente e prevenir recidivas (SAINZ et al., 2015). O suporte clínico (fluidoterapia, transfusões) é essencial em casos graves. O diagnóstico tardio pode levar a sequelas crônicas ou óbito (LITTLE, 2010).

CAPÍTULO 3

FUNDAMENTAÇÃO TEÓRICA: VISÃO COMPUTACIONAL

Tendo compreendido no capítulo anterior a complexidade biológica da anaplasmosse e as limitações do diagnóstico manual, este capítulo dedica-se a apresentar as ferramentas tecnológicas escolhidas para solucionar tal problema. Abordaremos os conceitos de Inteligência Artificial, Visão Computacional e a arquitetura de detecção de objetos YOLO.

3.1 Inteligência Artificial e Visão Computacional

A Inteligência Artificial (IA) é o grande campo da ciência que busca desenvolver sistemas capazes de realizar tarefas que, usualmente, requerem inteligência humana. Dentro dela, destaca-se a Aprendizagem Profunda (*Deep Learning*), que utiliza estruturas complexas chamadas Redes Neurais Convolucionais (CNNs) para aprender padrões a partir de dados, sendo treinadas por meio do algoritmo de retropropagação do erro (*backpropagation*) (RUMELHART et al., 1986).

O uso de redes neurais convolucionais em tarefas de visão computacional ganhou destaque após o trabalho de (KRIZHEVSKY et al., 2012), que demonstrou desempenho superior na classificação de imagens em larga escala ao empregar arquiteturas profundas treinadas com grandes volumes de dados.

Avanços posteriores demonstraram que o aumento da profundidade das redes neurais é um fator decisivo para o aprendizado de representações mais discriminativas. Simonyan e Zisserman (SIMONYAN; ZISSERMAN, 2014) evidenciaram que redes muito profundas, compostas por múltiplas camadas convolucionais empilhadas, apresentam desempenho superior em tarefas de reconhecimento visual.

Entretanto, o aumento excessivo da profundidade pode causar dificuldades no treinamento, como o desaparecimento do gradiente. Para mitigar esse problema, He et al. (HE et al., 2016) propuseram as redes residuais (ResNet), que utilizam conexões de atalho para facilitar o fluxo do gradiente durante o treinamento.

O *Deep Learning* revolucionou a Visão Computacional, área que capacita computadores a “ver” e interpretar imagens digitais. A aplicação dessas tecnologias em imagens médicas, como revisado por (ZHOU et al., 2021), consolidando o *deep learning* como o principal paradigma moderno da visão computacional (LECUN et al., 2015).

Nesse contexto, revisões abrangentes indicam que o uso de deep learning em imagens médicas apresenta desempenho consistente em tarefas de detecção e classificação, inclusive em cenários clínicos complexos (LITJENS et al., 2017).

3.2 Detecção de Objetos: A Arquitetura YOLOv8

Para este trabalho, não bastava apenas classificar se uma imagem continha ou não a doença; era necessário localizar onde a doença estava. Essa tarefa é chamada de Detecção de Objetos.

A arquitetura escolhida foi a YOLO (*You Only Look Once*), proposta originalmente por Redmon et al. (REDMON et al., 2016). Diferente de métodos antigos que varriam a imagem várias vezes, a YOLO processa a imagem inteira de uma única vez, o que a torna extremamente rápida e eficiente. Utilizamos a versão **YOLOv8**, lançada pela Ultralytics, que é considerada estado da arte em termos de equilíbrio entre velocidade e precisão (VARGHESE; SAMBATH, 2024).

O YOLOv8 utiliza uma abordagem *anchor-free* (livre de âncoras), o que simplifica o processo de treinamento e melhora a capacidade de generalização do modelo para detectar objetos de diferentes tamanhos e escalas, algo crucial para identificar plaquetas em diferentes ampliações microscópicas.

3.3 Trabalhos Relacionados (Estado da Arte)

A aplicação de IA para auxiliar no diagnóstico hematológico é uma área de pesquisa ativa. A Tabela 3.1 apresenta um comparativo entre este trabalho e outras pesquisas similares na área de detecção de hemoparasitas.

Nota-se que pesquisadores como Zhou et al. (2025) e Wang et al. (2023) obtiveram sucesso na detecção de *Babesia* e Malária, respectivamente, utilizando Deep Learning. A principal distinção deste trabalho reside no foco específico na *Anaplasma platys* e no desafio de treinar um modelo robusto com um *dataset* limitado, simulando uma condição real de escassez de dados médicos.

Autor (Ano)	Alvo (Doença)	Método	Dataset
(ZHOU et al., 2025)	<i>Babesia canis</i> (Cães)	Deep Learning	1.300+ imgs
(WANG et al., 2023)	<i>Plasmodium</i> (Malária)	YOLOv7	8.000+ imgs
Este Trabalho	<i>Anaplasma platys</i>	YOLOv8	44 imgs

Tabela 3.1: Comparativo de trabalhos relacionados na detecção de hemoparasitas.

CAPÍTULO 4

MATERIAIS E MÉTODOS

Este capítulo apresenta o detalhamento técnico e metodológico adotado para o desenvolvimento do projeto. São descritas as ferramentas de software utilizadas, o processo de construção e curadoria do conjunto de dados (*dataset*), as configurações de treinamento da rede neural e, por fim, as métricas selecionadas para a avaliação de desempenho do modelo proposto.

4.1 Ferramentas de Software

O projeto foi desenvolvido integralmente na linguagem de programação Python (versão 3.12.10). Para a tarefa de detecção de objetos, utilizou-se a arquitetura YOLOv8, implementada através da biblioteca oficial *Ultralytics*. A manipulação de imagens, incluindo a leitura e o processamento para visualização dos resultados, foi realizada com o auxílio da biblioteca OpenCV.

Na etapa de anotação das imagens (*labeling*), optou-se pela ferramenta online MakeSense.ai. A escolha desta ferramenta deve-se à sua interface intuitiva e à capacidade nativa de exportar as anotações no formato ‘.txt’ exigido pelo algoritmo YOLO. Para o gerenciamento e armazenamento estruturado das contagens e resultados das inferências, utilizou-se a biblioteca SQLite3.

4.2 Construção do *Dataset*

A qualidade e a representatividade do conjunto de dados são fatores determinantes em projetos de aprendizado de máquina supervisionado.

4.2.1 Coleta e Origem das Imagens

As imagens utilizadas neste estudo estão apresentadas integralmente no Apêndice A.

Dada a escassez de bancos de dados públicos padronizados contendo imagens microscópicas de *Anaplasma platys*, o conjunto de dados utilizado neste trabalho foi construído a partir de múltiplas fontes, adotando-se uma abordagem híbrida.

O *dataset* é composto por 44 imagens, na tabela 4.1 nota-se que 33 imagens (75%) foram cedidas pelo Hospital Veterinário do Instituto Federal Goiano – Campus Urutaí, provenientes de exames laboratoriais reais. Adicionalmente, 3 imagens (7%) foram fornecidas por uma clínica veterinária privada localizada na cidade de Goiânia, por intermédio de profissional da área.

As 8 imagens restantes (18%) foram obtidas a partir de fontes bibliográficas disponíveis online, incluindo livros técnicos e materiais científicos acessados por meio da internet, selecionados por apresentarem qualidade adequada e características morfológicas compatíveis com os objetivos do estudo.

Essa diversidade de origens contribuiu para aumentar a variabilidade do conjunto de dados, reduzindo possíveis vieses associados a uma única fonte de aquisição e favorecendo a capacidade de generalização do modelo treinado.

Origem	Quantidade	Percentual
Hospital Veterinário IF Goiano (Urutaí)	33	75%
Clínica Veterinária (Goiânia)	3	7%
Fontes públicas e literatura	8	18%
Total	44	100 %

Tabela 4.1: Distribuição das imagens do *dataset* segundo a origem.

Cabe destacar que o número reduzido de imagens disponíveis constitui uma limitação metodológica relevante. A literatura aponta que, em cenários de dados limitados, técnicas de *data augmentation* podem ser empregadas para aumentar artificialmente a diversidade do conjunto de treinamento, contribuindo para a melhoria da generalização de modelos de *deep learning* (SHORTEN; KHOSHGOFTAAR, 2019). Entretanto, tais técnicas não foram aplicadas neste trabalho, sendo indicadas como perspectiva para estudos futuros.

4.2.2 Anotação e Definição de Classes

O processo de anotação manual (*Ground Truth*) foi realizado individualmente em cada imagem, delimitando-se as plaquetas através de caixas envoltentes (*bounding boxes*). Para o

treinamento supervisionado, foram definidas duas classes distintas:

- **Plaquetas_saudaveis** (ID 0): Plaquetas com morfologia normal, sem inclusões visíveis.
- **Plaquetas_doentes** (ID 1): Plaquetas contendo a mórula característica de *Anaplasma platys*.

4.2.3 Divisão do *Dataset*

A separação dos dados é essencial para avaliar a capacidade de generalização do modelo e evitar o sobreajuste (*overfitting*), situação em que a rede neural passa a memorizar os exemplos de treinamento em vez de aprender padrões representativos.

O *dataset* foi particionado na proporção aproximada de 80% para treinamento e 20% para validação, conforme detalhado na Tabela 4.2. A divisão não foi realizada de forma aleatória, mas sim de maneira criteriosa, considerando a origem das imagens e a necessidade de controle metodológico.

O conjunto de treinamento foi composto por 35 imagens, sendo utilizadas as 8 imagens provenientes de livros técnicos e materiais científicos acessados por meio da internet, as 3 imagens cedidas por clínica veterinária privada localizada na cidade de Goiânia e 24 imagens oriundas do Hospital Veterinário do Instituto Federal Goiano – Campus Urutaí, totalizando 35 imagens.

Já o conjunto de validação foi constituído por 9 imagens, selecionadas exclusivamente dentre aquelas provenientes do Hospital Veterinário do Instituto Federal Goiano – Campus Urutaí, garantindo que o modelo fosse avaliado em dados reais não utilizados durante o treinamento.

Essa estratégia permitiu avaliar o desempenho do modelo em amostras independentes, preservando a coerência experimental e assegurando maior rigor na análise dos resultados.

Conjunto	Número de Imagens	Porcentagem
Treinamento (Train)	35	80%
Validação (Val)	9	20%
Total	44	100%

Tabela 4.2: Divisão do *dataset* de 44 imagens.

4.3 Configuração e Treinamento (train.py)

Para sistematizar o desenvolvimento do modelo e garantir a reprodutibilidade dos experimentos, estabeleceu-se um fluxo de trabalho estruturado. A figura 4.1 ilustra as etapas efetivamente implementadas neste projeto, desde a coleta inicial das imagens microscópicas até a obtenção do modelo final treinado. O processo compreende a anotação manual das imagens, a organização do *dataset* e sua divisão em conjuntos de treinamento e validação, seguida do treinamento supervisionado da rede YOLOv8. O ciclo de aprendizado é conduzido automaticamente pelo framework, utilizando critério de parada antecipada (*early stopping*) baseado na métrica de validação, não havendo intervenção manual ou ajuste iterativo automático de hiperparâmetros durante o treinamento.




Figura 4.1: Fluxograma metodológico e representação visual das etapas de anotação e inferência do modelo YOLOv8.

O treinamento da rede neural foi orquestrado pelo script `train.py`. Este algoritmo é responsável por carregar a arquitetura base, ler o arquivo de configuração do *dataset* e gerenciar o ciclo de aprendizado, salvando os pesos do melhor modelo obtido (`best.pt`).

4.3.1 Arquivo de Configuração do *Dataset*

Para a correta interpretação dos dados pelo framework YOLO, foi criado o arquivo `plaqueas.yaml`. Este arquivo de configuração define os caminhos absolutos para os diretórios de treino e validação, além de especificar o número de classes (`nc: 2`) e seus respectivos nomes.

4.3.2 Hiperparâmetros de Treinamento

Os hiperparâmetros utilizados para o treinamento estão resumidos na Tabela 4.3. Utilizou-se a técnica de *Transfer Learning* partindo do modelo pré-treinado `yolov8n.pt` (versão Nano), ideal para cenários com recursos computacionais limitados. O treinamento foi configurado para um máximo de 300 épocas, com um critério de parada antecipada (*early stopping*) definido pela paciência de 100 épocas sem melhoria na métrica de validação.

Parâmetro	Valor
Modelo Base	<code>yolov8n.pt</code>
Épocas (Epochs)	300
Paciência (Patience)	100
Tamanho do Lote (Batch Size)	8
Resolução (imgsz)	640
Otimizador	Auto

Tabela 4.3: Hiperparâmetros utilizados no treinamento do YOLOv8.

4.4 Inferência e Análise de Resultados (`predict_with_db.py`)

Após a etapa de treinamento, a validação do modelo foi realizada através do script `predict_with_db.py`. Este algoritmo carrega os pesos treinados (`best.pt`) e executa a inferência no conjunto de validação, processando os resultados tanto visualmente quanto estatisticamente.

4.4.1 Processamento em Lote

O script realiza a leitura sequencial das imagens de validação. Devido à limitação do número de amostras no *dataset*, ajustou-se o limiar de confiança (*confidence threshold*) para

0.1 (10%), visando aumentar a sensibilidade do modelo na detecção de objetos difíceis. As imagens resultantes, contendo as caixas delimitadoras previstas, são salvas automaticamente no diretório de resultados.

4.4.2 Persistência de Dados

Para permitir uma análise quantitativa posterior, o sistema contabiliza automaticamente o número de instâncias detectadas para cada classe. Estes dados, juntamente com metadados como nome do arquivo e data da análise, são persistidos em um banco de dados relacional SQLite (`resultados_analises.db`).

4.5 Métricas de Avaliação

A eficácia do modelo foi mensurada utilizando as métricas de desempenho estabelecidas como padrão na literatura de detecção de objetos, especificamente a Matriz de Confusão e a Precisão Média (mAP) (ULTRALYTICS, 2024b; ULTRALYTICS, 2024a). Estas métricas permitem uma análise quantitativa detalhada sobre a capacidade do modelo em localizar e classificar corretamente as plaquetas.

4.5.1 Matriz de Confusão

A Matriz de Confusão é uma ferramenta tabular que permite visualizar o desempenho do algoritmo, confrontando as classificações previstas pelo modelo com as classificações reais (*Ground Truth*). Ela explicita quatro possíveis resultados para cada classe:

- **Verdadeiros Positivos (VP):** O modelo detectou corretamente a presença de uma plaqueta (saudável ou doente).
- **Falsos Positivos (FP):** O modelo detectou uma plaqueta onde não existia (ex: confundiu uma sujeira com uma mórula).
- **Falsos Negativos (FN):** O modelo deixou de detectar uma plaqueta que estava presente na imagem.
- **Verdadeiros Negativos (VN):** O modelo corretamente ignorou o fundo da imagem (esta métrica geralmente não é contabilizada diretamente em detecção de objetos).

4.5.2 Precisão Média (mAP)

A métrica principal adotada foi a Precisão Média (*Mean Average Precision* - mAP). O mAP é calculado a partir da curva de Precisão x Revocação (Precision-Recall) e resume a qualidade global do modelo em um único valor entre 0 e 1 (ou 0% e 100%).

Neste trabalho, utilizou-se especificamente a métrica **mAP@50**, que considera uma detecção como correta apenas se a área de sobreposição (IoU - *Intersection over Union*) entre a caixa predita e a caixa real for superior a 50%.

CAPÍTULO 5

RESULTADOS E DISCUSSÃO

Este capítulo apresenta os dados obtidos a partir do treinamento e validação do modelo YOLOv8. Inicialmente, são expostas as métricas quantitativas de desempenho, seguidas por uma análise detalhada da Matriz de Confusão. Posteriormente, realiza-se uma análise qualitativa das predições em imagens microscópicas, discutindo os acertos e erros do modelo frente às limitações do estudo.

5.1 Ambiente de Treinamento e Execução

O treinamento foi realizado em infraestrutura local, utilizando um processador 13th Gen Intel(R) Core(TM) i5-13420H com 8,00 GB de memória RAM. O componente crítico para o desempenho foi a GPU dedicada NVIDIA GeForce RTX 3050 (6GB). A utilização da tecnologia CUDA permitiu a aceleração dos cálculos da rede neural. O modelo base *yolov8n.pt* foi treinado por 300 épocas, com um critério de parada antecipada (*early stopping*) de 100 épocas, totalizando aproximadamente 1 hora e 10 minutos de processamento.

5.2 Análise das Métricas de Desempenho

Para avaliar a eficácia do aprendizado, analisaram-se os gráficos de métricas e perdas apresentados na Figura 5.1 e os valores finais na Tabela 5.1.




Figura 5.1: Gráficos de métricas e perdas durante o treinamento do YOLOv8.

A análise da Figura 5.1 permite as seguintes observações:

- **Curvas de Perda (Loss):** Observa-se um decaimento consistente nas curvas de perda de treinamento, referentes à localização (*box_loss*) e à classificação (*cls_loss*). Esse comportamento indica que a rede neural foi capaz de minimizar progressivamente o erro na delimitação e identificação das plaquetas.
- **Métricas de Validação:** O desempenho no conjunto de validação demonstra a capacidade de generalização do modelo:
 - **Precisão (Precision):** A curva estabilizou-se próxima a 60%, indicando a proporção de detecções corretas em relação ao total de detecções positivas.
 - **Revocação (Recall):** A métrica atingiu aproximadamente 70%, o que reflete a sensibilidade do modelo em encontrar as plaquetas doentes presentes nas amostras.
 - **mAP50:** O índice de Precisão Média com limiar de IoU de 50% atingiu um pico de 60%. Este valor evidencia que o modelo obteve sucesso razoável na tarefa de detecção, considerando as limitações do conjunto de dados.
 - **mAP50-95:** A média de precisão sob limiares mais rigorosos (até 95%) ficou em torno de 30%, indicando que o ajuste fino das caixas delimitadoras ainda pode ser aprimorado com um *dataset* mais robusto.

A Tabela 5.1 resume os valores de pico médio alcançados pelo modelo.

Métrica	Valor Aproximado
mAP50 (Precisão Média @ IoU 0.50)	0.60 (60%)
mAP50-95 (Média de Precisão Geral)	0.30 (30%)
Precision (Precisão)	0.60
Recall (Revocação)	0.70

Tabela 5.1: Métricas de desempenho finais no conjunto de validação (Pico Médio).

5.3 Análise Crítica dos Erros

A Matriz de Confusão (Figura 5.2 e Tabela 5.2) permite identificar a natureza dos erros cometidos pelo classificador no conjunto de validação. O modelo processou as 9 imagens de validação, identificando um total de 32 plaquetas (17 saudáveis e 15 doentes) e gerando detecções adicionais em áreas de fundo.




Figura 5.2: Matriz de confusão do conjunto de validação.

Predição (Modelo)	Verdade (Gabarito)		
	Plaq. Saudáveis	Plaq. Doentes	Background
Plaq. Saudáveis	5	2	2
Plaq. Doentes	8	10	10
Background	4	3	–
Total (Gabarito)	17	15	12

Tabela 5.2: Matriz de Confusão detalhada do conjunto de validação.

Ressalta-se que os valores apresentados na matriz de confusão referem-se ao número de instâncias detectadas *bounding boxes* no conjunto de validação, e não ao número de imagens. Em tarefas de detecção de objetos, uma única imagem pode conter múltiplas instâncias, o que justifica a soma total de 44 ocorrências avaliadas.

A análise dos dados da Tabela 5.2 revela dois comportamentos principais:

- **Falsos Positivos (Sensibilidade ao Ruído):** O modelo classificou incorretamente 8 plaquetas saudáveis e 10 elementos de fundo como "Plaquetas Doentes". Isso sugere uma dificuldade em distinguir características visuais sutis, provavelmente devido à escassez de exemplos negativos (saudáveis) variados no treinamento. O algoritmo tende a sinalizar anomalias ou sujeiras na lâmina como infecções.
- **Falsos Negativos (Omissões):** Observa-se que 4 plaquetas saudáveis e 3 doentes não foram detectadas (classificadas como background). Isso indica que, em certos casos, o modelo não teve confiança suficiente (acima do limiar de 10%) para gerar uma caixa delimitadora.
- **Observação sobre o Background:** O quadrante inferior direito da matriz aparece vazio, pois não se contabilizam os verdadeiros negativos do fundo (áreas vazias corretamente ignoradas), uma vez que o fundo da imagem é vasto e não anotado.

5.4 Análise Qualitativa

Nesta seção, são apresentados os resultados visuais da inferência nas imagens de validação, ilustrando os padrões discutidos.

A Figura 5.3 demonstra um caso de sucesso, onde o modelo localizou e classificou corretamente as três plaquetas infectadas, evidenciando o aprendizado da característica visual da mórula da *Anaplasma*.




Figura 5.3: Detecção correta de plaquetas doentes.

Na Figura 5.4, verifica-se a capacidade de identificar plaquetas saudáveis. Contudo, nota-se um falso negativo no canto superior direito, onde uma estrutura celular foi ignorada.




Figura 5.4: Detecção de plaquetas saudáveis e presença de falso negativo.

A robustez do modelo em cenários com alta densidade celular é observada na Figura 5.5. Mesmo com a complexidade visual, as anotações foram realizadas corretamente.




Figura 5.5: Exemplo de detecção correta em campo denso.

A Figura 5.6 demonstra a precisão na detecção de instâncias isoladas, com a classificação correta de uma plaqueta doente.




Figura 5.6: Detecção individual correta.

Um erro de classificação significativo é ilustrado na Figura 5.7, onde o modelo identificou incorretamente hemácias como plaquetas (indicado pela seta preta).




Figura 5.7: Erro de classificação: Hemácia identificada como plaqueta.

A Figura 5.8 reforça que a visibilidade clara da mórula favorece o acerto do modelo na detecção de plaquetas doentes.




Figura 5.8: Detecção correta de plaqueta doente.

A Figura 5.9 exemplifica as limitações de consistência, apresentando simultaneamente um Falso Negativo (omissão) e um Falso Positivo (fundo detectado como plaqueta).



Figura 5.9: Ocorrência simultânea de Falso Positivo e Falso Negativo.

A tendência à geração de múltiplos falsos positivos é evidenciada na Figura 5.10. Além de omitir duas plaquetas doentes (setas vermelhas), o modelo classificou erroneamente uma hemácia (seta preta), confirmando a dificuldade em ambientes com ruído visual.




Figura 5.10: Presença de Falsos Negativos e Falso Positivo na mesma amostra.

Finalmente, a Figura 5.11 apresenta um acerto na identificação de plaquetas saudáveis, demonstrando o potencial de generalização do modelo.




Figura 5.11: Detecção correta de plaquetas saudáveis.

5.5 Discussão Geral

A partir da análise dos resultados, apresentam-se as seguintes conclusões sobre o desenvolvimento do trabalho.

5.5.1 Implicações Práticas

Considerando o mAP de 60% e a ocorrência de falsos positivos, o modelo não substitui a análise do patologista, mas demonstra viabilidade como ferramenta de triagem automatizada.

Em um laboratório, o sistema poderia atuar como um filtro inicial, analisando integralmente as lâminas e sinalizando amostras suspeitas. Um modelo com alta sensibilidade (que prioriza não perder casos doentes, mesmo gerando alguns falsos positivos) é vantajoso nesse cenário, permitindo que o especialista foque sua atenção na verificação das lâminas pré-selecionadas.

5.5.2 Limitações do Estudo

A principal limitação deste estudo reside no tamanho do *dataset* utilizado (44 imagens). A escassez de dados restringiu a capacidade do modelo de aprender representações robustas, especialmente para distinguir plaquetas saudáveis de artefatos ou hemácias. A literatura técnica, como (CANDEMIR et al., 2021), corrobora que o desempenho de redes neurais profundas é fortemente dependente do volume de dados de treinamento.

5.5.3 Comparação com Trabalhos Relacionados

Ao comparar os resultados obtidos com o estado da arte (conforme Tabela 3.1 no Capítulo 3), nota-se que precisões superiores a 90% são geralmente alcançadas em estudos que utilizam milhares de imagens. O resultado de 60% de mAP obtido neste trabalho é promissor, considerando a restrição de dados, e sugere que a metodologia YOLOv8 é adequada, dependendo primordialmente da expansão do banco de imagens para atingir níveis de desempenho clínico.

Este capítulo final visa sintetizar os pontos abordados: revisita-se o que foi proposto, o que de fato se conseguiu alcançar e quais são os próximos passos lógicos para, futuramente, dar-se continuidade a esta pesquisa.

6.1 Retomada dos Objetivos

O objetivo geral deste trabalho consistiu em desenvolver e avaliar um modelo de YOLOv8 para detectar plaquetas saudáveis e infectadas por *Anaplasma platys*. Conforme os resultados apresentados, o objetivo foi alcançado de forma que um protótipo funcional foi construído.

Ao analisar os objetivos específicos, observa-se que:

- A revisão bibliográfica (Capítulo 3) foi realizada, fornecendo a base teórica necessária.
- O *dataset* híbrido de 44 imagens foi construído e anotado (Capítulo 4).
- O modelo YOLOv8 foi treinado e avaliado (Capítulo 5), provando ser capaz de aprender a tarefa (atingindo 60% de mAP50).
- O script de predição (`predict_with_db.py`) foi desenvolvido com êxito, analisando as imagens e salvando os resultados no banco de dados.

6.2 Considerações Finais

A principal contribuição deste trabalho foi a prova de conceito. Demonstrou-se que é viável utilizar o YOLOv8 para o diagnóstico auxiliar da anaplasmosse canina. O modelo

aprendeu a identificar as mórulas de *Anaplasma* (a classe `Plaquetas_doentes`).

Conforme discutido no Capítulo 5, o desempenho de 60% não é perfeito, e o modelo tende a apresentar falsos positivos (demonstrando alta sensibilidade). No entanto, essa característica, que pode parecer uma fraqueza, é o que o torna uma ferramenta de triagem promissora. Tornou-se evidente que o gargalo do projeto não reside na arquitetura YOLOv8, mas sim na quantidade de dados.

6.3 Trabalhos Futuros

A partir das limitações encontradas, os próximos passos para a evolução deste protótipo caracterizando os trabalhos futuros são:

- **Expansão Massiva do *Dataset*:** Esta constitui a prioridade principal. O *dataset* de 44 imagens necessita ser expandido para centenas ou milhares. O desempenho de modelos de *deep learning* em cenários com dados limitados representa a principal barreira a ser superada. Um *dataset* maior e mais variado é essencial para reduzir a taxa de falsos positivos.
- **Exploração de *Data Augmentation*:** Além da coleta de mais imagens reais, seria interessante explorar técnicas avançadas de *data augmentation* (aumento de dados sintético). Estudos como o de (CHANDOLA et al., 2024) demonstram como isso pode enriquecer artificialmente a variedade dos dados de treino.
- **Treinamento em GPU com Modelos Maiores:** Com um *dataset* robusto, poder-se-ia experimentar modelos maiores (como o YOLOv8-M ou -L), que possuem maior capacidade de generalização ("inteligência"), mas que exigem mais dados e poder computacional.
- **Validação Clínica:** O passo final seria submeter o protótipo a uma validação clínica rigorosa, comparando seus resultados lado a lado com os de patologistas experientes e com o diagnóstico de PCR.

APÊNDICE A



IMAGENS DO *DATASET* UTILIZADO









Este apêndice apresenta integralmente as 44 imagens microscópicas utilizadas no treinamento e validação do modelo proposto neste trabalho. A inclusão completa do *dataset* justifica-se pelo reduzido número de amostras disponíveis e visa garantir transparência metodológica, rastreabilidade dos dados e reprodutibilidade científica.







As imagens estão organizadas de acordo com sua origem, conforme descrito no Capítulo de Metodologia.







A.1 Imagens do Hospital Veterinário do IF Goiano – Campus Urutaí







Esta seção reúne 33 imagens provenientes de exames laboratoriais reais, cedidas pelo Hospital Veterinário do Instituto Federal Goiano – Campus Urutaí.



























A.2 Imagens provenientes de clínica veterinária privada (Goiânia)



Esta seção apresenta 3 imagens cedidas por uma clínica veterinária privada localizada na cidade de Goiânia, por intermédio de profissional da área.



A.3 Imagens obtidas de fontes públicas online

As imagens desta seção foram obtidas a partir de fontes públicas confiáveis, incluindo artigos científicos e bancos de imagens digitais, totalizando 8 imagens selecionadas por sua qualidade e compatibilidade morfológica com o objeto de estudo.





REFERÊNCIAS BIBLIOGRÁFICAS

- ACOSTA-ESPAÑA, J. D.; HERRERA-YELA, A.; ALTAMIRANO-JARA, J. B. et al. The epidemiology and clinical manifestations of anaplasmosis in humans: A systematic review of case reports. *Journal of Infection and Public Health*, Elsevier, v. 18, p. 102765, 2025.
- ATIF, F. A.; MEHNAZ, S.; QAMAR, M. F. et al. Epidemiology, diagnosis, and control of canine infectious cyclic thrombocytopenia and granulocytic anaplasmosis: Emerging diseases of veterinary and public health significance. *Veterinary Sciences*, MDPI, v. 8, n. 12, p. 312, 2021.
- CANDEMIR, S.; NGUYEN, X. V.; FOLIO, L. R. et al. Training strategies for radiology deep learning models in data-limited scenarios. *Radiology: Artificial Intelligence*, Radiological Society of North America, v. 3, n. 6, p. e210014, 2021.
- CHANDOLA, Y.; UNİYAL, V.; BACHHETI, Y. et al. Data augmentation techniques applied to medical images. *Int J Res Publ Rev*, v. 5, n. 7, p. 483–501, 2024.
- DYACHENKO, V.; PANTCHEV, N.; BALZER, H. J. et al. First case of anaplasma platys infection in a dog from croatia. *Parasites & vectors*, Springer, v. 5, n. 1, p. 49, 2012.
- ESTEVA, A.; KUPREL, B.; NOVOA, R. A.; KO, J.; SWETTER, S. M.; BLAU, H. M.; THRUN, S. Dermatologist-level classification of skin cancer with deep neural networks. *nature*, Nature Publishing Group UK London, v. 542, n. 7639, p. 115–118, 2017.
- HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep residual learning for image recognition. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2016. p. 770–778.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, v. 25, 2012.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *nature*, Nature Publishing Group UK London, v. 521, n. 7553, p. 436–444, 2015.
- LITJENS, G.; KOOL, T.; BEJNORDI, B. E.; SETIO, A. A. A.; CIOMPI, F.; GHAFLOORIAN, M.; LAAK, J. A. V. D.; GINNEKEN, B. V.; SÁNCHEZ, C. I. A survey on deep learning in medical image analysis. *Medical image analysis*, Elsevier, v. 42, p. 60–88, 2017.

- LITTLE, S. E. Ehrlichiosis and anaplasmosis in dogs and cats. *Veterinary Clinics of North America: Small Animal Practice*, Elsevier, v. 40, n. 6, p. 1121–1140, 2010.
- MARTINESCU, G.-V.; IVĂNESCU, L.; ȘTEFĂNESCU, R. et al. Strategies for the diagnosis of granulocytic anaplasmosis in two naturally infected dogs. *Animals*, MDPI, v. 14, n. 1, p. 49, 2024.
- NEER, T. M.; BREITSCHWERDT, E. B.; GREENE, R. T.; LAPPIN, M. R. Consensus statement on ehrlichial disease of small animals from the infectious disease study group of the acvim. *Journal of Veterinary Internal Medicine*, Wiley Online Library, v. 16, n. 3, p. 309–315, 2002.
- OTRANTO, D.; TESTINI, G.; DANTAS-TORRES, F. et al. Diagnosis of canine vector-borne diseases in young dogs: a longitudinal study. *Journal of Clinical Microbiology*, American Society for Microbiology, v. 48, n. 9, p. 3316–3324, 2010.
- REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHADI, A. You only look once: Unified, real-time object detection. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2016. p. 779–788.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. *nature*, Nature Publishing Group UK London, v. 323, n. 6088, p. 533–536, 1986.
- SAINZ, A.; ROURA, X.; MIRÓ, G.; ESTRADA-PEÑA, A.; KOHN, B.; HARRUS, S.; SOLANO-GALLEGU, L. Guideline for veterinary practitioners on canine ehrlichiosis and anaplasmosis in europe. *Parasites & Vectors*, BioMed Central, v. 8, n. 1, p. 75, 2015.
- ScienceDirect AI. *Overview of Canine Anaplasmosis*. 2024. Summary generated based on Scopus abstracts. Acessado em: Janeiro de 2026. Disponível via ScienceDirect.
- ScienceDirect AI. *Overview of Tick-Borne Infections in Dogs*. 2024. Summary generated based on Scopus abstracts. Acessado em: Janeiro de 2026. Disponível via ScienceDirect.
- SHORTEN, C.; KHOSHGOFTAAR, T. M. A survey on image data augmentation for deep learning. *Journal of big data*, Springer, v. 6, n. 1, p. 1–48, 2019.
- SILVA, L. S.; PINHO, F. A. d.; PIRES, L. V. et al. Canine infection by ehrlichia canis and anaplasma platys in the semiarid region of brazil: frequency and molecular characterization. *Revista Brasileira de Saúde e Produção Animal*, SciELO, v. 26, p. e20250002, 2025.
- SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014.
- ULTRALYTICS. *Matriz de Confusão Explicada*. 2024. <<https://www.ultralytics.com/pt/glossary/confusion-matrix>>. Acessado em: 13 de novembro de 2025.
- ULTRALYTICS. *Precisão Média (mAP) Explicada*. 2024. <<https://www.ultralytics.com/pt/glossary/mean-average-precision-map>>. Acessado em: 13 de novembro de 2025.
- VARGHESE, R.; SAMBATH, M. Yolov8: A novel object detection algorithm with enhanced performance and robustness. In: *IEEE. 2024 International conference on advances in data engineering and intelligent computing systems (ADICS)*. [S.l.], 2024. p. 1–6.

WANG, G.; LUO, G.; LIAN, H. et al. Application of deep learning in clinical settings for detecting and classifying malaria parasites in thin blood smears. In: OXFORD UNIVERSITY PRESS US. *Open forum infectious diseases*. [S.l.], 2023. v. 10, n. 11, p. ofad469.

ZHOU, S. K.; GREENSPAN, H.; DAVATZIKOS, C. et al. A review of deep learning in medical imaging: Imaging traits, technology trends, case studies with progress highlights, and future promises. *Proceedings of the IEEE*, IEEE, v. 109, n. 5, p. 820–838, 2021.

ZHOU, S. K.; GREENSPAN, H.; DAVATZIKOS, C. et al. Automated detection of canine babesia parasite in blood smear images using deep learning and contrastive learning techniques. *Parasitologia*, MDPI, v. 5, n. 2, p. 23, 2025.