

Detecção Automática de Macrófagos em Esfregaço de Medula Óssea Canina com Deep Learning

Rafael Luz Araújo^{1,2}, Viviane B. L. Dias¹, Armando Luz Borges¹,
Lucas B. M. de Souza¹, Kawan Sousa Dias¹, Clara E. S. Sátiro¹,
Clésio de A. Gonçalves³, Ana C. L. Pacheco¹, Romuere R. V. e Silva¹

¹Universidade Federal do Piauí (UFPI) – Picos – PI – Brasil

²Instituto Federal do Piauí (IFPI) – Picos – PI – Brasil

³Instituto Federal do Piauí (IFPI) – Paulistana – PI – Brasil

rafaluzaraajo@ifpi.edu.br, romuere@ufpi.edu.br

Abstract. *Canine visceral leishmaniasis (CVL) is a neglected zoonosis affecting dogs and humans, posing significant public health challenges due to diagnostic difficulties. This study aimed to enhance the detection of macrophages in microscopic images of canine bone marrow aspirates by employing deep learning techniques. The YOLOv8 model was utilized in conjunction with data augmentation strategies, including color adjustments and geometric transformations. The results were promising, achieving a recall of 0,79 and an mAP50 of 0,85, indicating high sensitivity and precision in detection. This step is crucial for CVL diagnosis, as accurate identification of macrophages facilitates the subsequent detection of amastigotes.*

Resumo. *A Leishmaniose Visceral Canina (LVC) é uma zoonose negligenciada que afeta cães e humanos, representando um desafio significativo para a saúde pública devido às dificuldades diagnósticas. Este estudo buscou aprimorar a detecção de macrófagos em imagens microscópicas do material aspirado da medula óssea canina. Para tal, utilizou-se o modelo YOLOv8 combinado com estratégias de aumento de variabilidade, incluindo ajustes de cores e transformações geométricas. Os resultados foram promissores, alcançando um recall de 0,79 e um mAP50 de 0,85, indicando alta sensibilidade e precisão na detecção. Essa etapa é crucial para o diagnóstico da LVC, pois a identificação precisa dos macrófagos facilita a subsequente detecção das amastigotas.*

1. Introdução

A Leishmaniose Visceral Canina (LVC) é uma zoonose considerada doença tropical negligenciada que afeta principalmente cães e humanos, ocasionada pelo protozoário flagelar do gênero *Leishmania* e transmitida pela picada de insetos hematófagos conhecidos como flebotomíneos, com impacto na saúde animal e humana [Marcondes and Day 2019]. Os cães são os principais reservatórios urbanos, contribuindo para a manutenção do ciclo urbano e transmissão da doença para seres humanos [PAHO 2017]. A Leishmaniose Visceral (LV) se espalha pelo organismo via sangue e linfa, afetando órgãos como fígado, baço e medula óssea [Álvaro 2022]. Em humanos, causa febre prolongada, anemia e aumento do fígado e baço, podendo ser fatal sem tratamento [Kumar and Nylén 2012].

Em animais, os principais sintomas são dermatites e úlceras cutâneas, anemia, lesões oculares, insuficiência renal, febre, má condição corporal, linfadenopatia, esplenomegalia e hepatomegalia. Entretanto, na maioria dos casos, os animais não manifestam sintomas, mesmo mantendo um papel ativo na transmissão da leishmaniose [Koutinas and Koutinas 2014]. Não há vacina contra as leishmanioses humanas. As principais medidas de prevenção e combate à doença baseiam-se no controle de vetores e reservatórios, proteção individual, diagnóstico precoce e tratamento dos doentes, manejo ambiental e educação em saúde. Dessa maneira, a detecção precoce em cães é essencial para conter a transmissão, especialmente no Brasil, que concentra 90% dos casos na América Latina [da Saúde 2025].

O diagnóstico da LVC é complexo e desafiador, pois não existem testes com 100% de sensibilidade e especificidade. Testes sorológicos, como a Reação de Imunofluorescência Indireta (RIFI) e o Ensaio Imunoenzimático (ELISA), são úteis para triagem, mas podem apresentar limitações em termos de sensibilidade e especificidade [Silva et al. 2014]. O exame parasitológico utilizando material aspirado da medula óssea é considerado uma das abordagens mais eficazes, pois envolve a visualização direta das formas amastigotas do parasita, especialmente dentro e ao redor dos macrófagos, células do sistema imunológico que fagocitam patógenos e participam da resposta inflamatória [Silva 2007]. No entanto, esse procedimento enfrenta obstáculos. Por exemplo, conforme diretrizes do Ministério da Saúde, uma amostra é considerada negativa somente após a análise de 200 campos microscópicos utilizando objetiva de imersão. Além disso, a semelhança morfológica entre diferentes estruturas biológicas pode levar a erros de identificação, e o processo manual é suscetível à experiência e à fadiga do especialista, o que aumenta o risco de erros e imprecisões [Antunes et al. 2018].

Entre 2017 e 2024, o Brasil registrou 50.372 novos casos de LV em humanos, com uma taxa de letalidade de 7,03%, um valor preocupante dada a gravidade da doença. A região Nordeste apresenta índices elevados, com destaque para os estados do Maranhão (7.547 casos) e Ceará (5.947 casos). A persistência desses altos números reforça a necessidade de métodos diagnósticos mais modernos e eficazes, capazes de superar as limitações das abordagens tradicionais e contribuir para o controle da disseminação da doença [da Saúde 2025]. A aplicação de métodos de Visão Computacional e Aprendizado de Máquina no diagnóstico da LVC tem capacidade de agilizar a análise microscópica, reduzir erros humanos e viabilizar o uso em larga escala [Aziz et al. 2020, Eder et al. 2021]. No entanto, desafios persistem na adaptação dessas técnicas, especialmente na detecção de macrófagos e parasitas [Gonçalves et al. 2023].

Neste contexto, este estudo propõe a aplicação de técnicas de *deep learning*, utilizando o modelo *You Only Look Once*, versão 8 (YOLOv8) [Jocher et al. 2023], para a detecção automática de macrófagos em imagens de lâminas provenientes do exame parasitológico (microscopia) de material aspirado da medula óssea canina. A identificação dos macrófagos é estratégica, pois as formas amastigotas costumam estar no seu interior e ao redor, sendo sua detecção essencial para a identificação automatizada da infecção.

2. Trabalhos Relacionados

Realizou-se uma busca por estudos que aplicam técnicas de visão computacional e aprendizado de máquina na detecção de LVC em imagens de lâminas de esfregaço de medula

óssea canina. No entanto, a maioria dos artigos encontrados não aborda diretamente esse foco. Apenas um estudo, de [Sadeghi et al. 2024], apresentou uma abordagem relevante, propondo o modelo *LeishFuNet* para detectar amastigotas em lâminas microscópicas, utilizando aprendizado profundo para o processamento de imagens médicas.

Além desse trabalho, outras pesquisas exploram a aplicação de inteligência artificial na Leishmaniose. [Cannet et al. 2023] investigaram a identificação de flebotomíneos utilizando às características visuais únicas geradas pela interação da luz com as asas dos insetos, que podem ser capturadas e analisadas para diferenciação entre espécies através de redes neurais. [Coelho et al. 2023] e [Larios et al. 2021] analisaram, respectivamente, o uso de espectroscopia ultravioleta (UV) e infravermelho com transformada de Fourier (FTIR) combinadas com modelos de aprendizado de máquina, como a Máquina de Votores de Suporte (SVM) e a Floresta Aleatória (*Random Forest*) para diagnóstico da LVC, reforçando o potencial da automação no diagnóstico da doença.

Apesar da relevância desses estudos, a escassez de trabalhos específicos sobre a detecção automatizada de macrófagos em amostras caninas limita a possibilidade de comparações métricas diretas. Dessa forma, optamos por incluir em nossa análise estudos focados na LV humana, que utilizam abordagens semelhantes, permitindo uma base comparativa mais ampla para o desenvolvimento de métodos diagnósticos aplicáveis em diferentes contextos. A Tabela 1 apresenta os trabalhos selecionados por utilizarem metodologias que permitem a comparação métrica com a abordagem proposta.

Tabela 1. Resumo dos trabalhos relacionados sobre LV em humanos.

Trabalho	Imagens (Quantidade)	Proposta	Metodologia
[Gonçalves et al. 2022]	Parasitologia - medula óssea (151)	Classificação	<i>Deep Learning</i> (CNNs pré-treinadas)
[Górriz et al. 2018]	Parasitologia - culturas celulares experimentais (45)	Segmentação	<i>Deep Learning</i> (U-Net)
[Isaza-Jaimes et al. 2020]	Parasitologia - medula óssea (45)	Detecção	Difusão anisotrópica + operadores de gradiente + análise de mapas polares
[Neves et al. 2014]	Parasitologia - culturas celulares experimentais (44)	Detecção	Detecção de <i>blobs</i> + análise de concavidade de contornos

Em [Górriz et al. 2018], foi proposto a segmentação de parasitas de Leishmania com a *U-Net*, alcançando um *F1-Score* de 77,7%. Contudo, o tamanho do *dataset*, apenas 45 imagens, pode comprometer a generalização do modelo. No trabalho de [Gonçalves et al. 2022], explorou-se a classificação de LV utilizando 151 imagens com a *LeNet* e CNNs pré-treinadas, como *InceptionResNetV2* e *NASNetLarge*. A melhor arquitetura foi a *LeNet* com *recall* de 64% e acurácia de 78,7%, mas o custo computacional de treinar a *LeNet* do zero limita sua aplicabilidade em cenários com restrições de hardware.

Em [Neves et al. 2014] os autores focaram na detecção e contagem de parasitas e macrófagos em imagens fluorescentes, combinando detecção de *blobs* e análise de concavidade de contornos, alcançando precisão de 81,55% e *F1-Score* de 84,48%. Contudo, dificuldades na segmentação de parasitas muito próximos afetam a acurácia da contagem. [Isaza-Jaimes et al. 2020] abordaram a detecção de Leishmania em uma base pública com 45 imagens, atingindo uma acurácia de 80%. Entretanto, o estudo não utilizou aprendizado profundo, o que pode limitar a precisão em cenários mais complexos.

Esses trabalhos demonstram avanços na automação do diagnóstico da LV, mas enfrentam desafios como custo computacional ao treinar modelos de *deep learning* do zero, bases de dados limitadas e dificuldades na segmentação de estruturas biológicas. Essas limitações reforçam a necessidade de modelos mais eficientes, capazes de detectar macrófagos e amastigotas com precisão, o que motiva a proposta deste estudo.

3. Metodologia

A metodologia proposta nesta pesquisa visa à detecção automática de macrófagos em imagens de lâminas de medula óssea canina, seguindo três etapas principais: 1) aquisição de imagens; 2) detecção de macrófagos; e 3) análise dos resultados, conforme ilustrado na Figura 1.

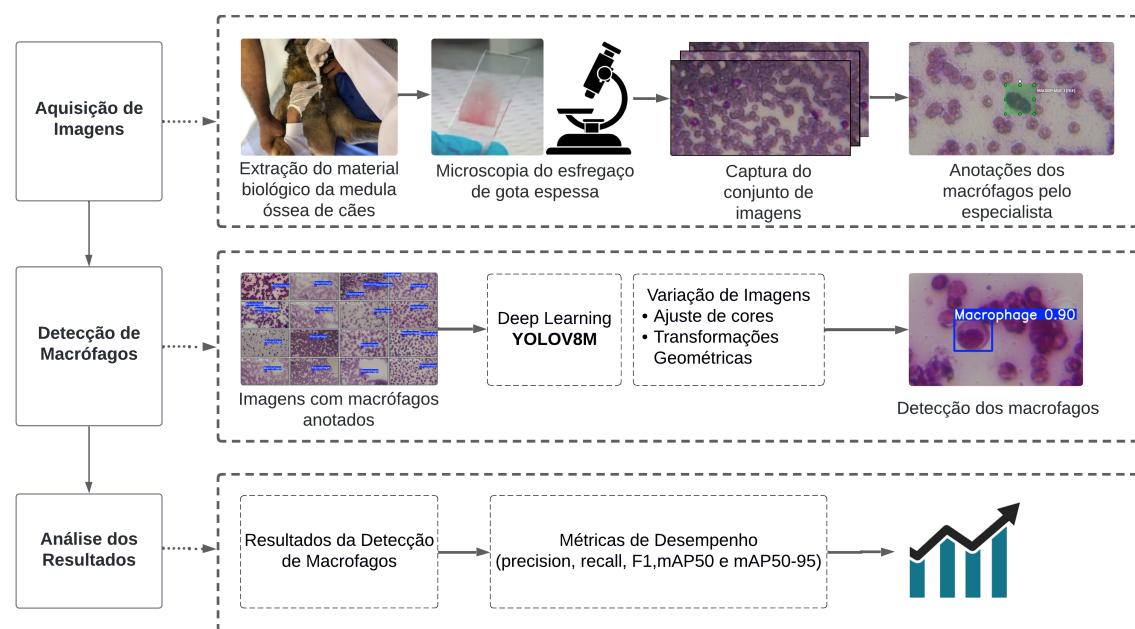


Figura 1. Fluxograma da metodologia proposta.

3.1. Aquisição de Imagens

O conjunto de dados utilizado neste estudo foi obtido a partir da captura de imagens digitais de lâminas histológicas previamente preparadas no âmbito do projeto "Diagnóstico parasitológico da leishmaniose: Avaliação comparativa da acurácia diagnóstica dos principais sítios de coleta", aprovado pelo Comitê de Ética para o Uso de Animais da Universidade Estadual do Ceará (CEUA-UECE), sob o número de parecer 3413082/2014. As lâminas foram fornecidas por um dos autores deste trabalho. A coleta de imagens e a anotação dos elementos de interesse (como macrófagos e amastigotas) foram realizadas

exclusivamente a partir desse material, não havendo qualquer nova intervenção animal. Todas as atividades respeitaram os princípios éticos de experimentação com animais.

A coleta do conjunto de imagens foi realizada em colaboração com o Laboratório de Parasitologia, Ecologia e Doenças Negligenciadas da Universidade Federal do Piauí (LAPEDONE/UFPI). As imagens foram obtidas a partir de amostras biológicas retiradas da medula óssea do fêmur de nove cães, analisadas em lâminas microscópicas. O processo foi conduzido com um microscópio focalizado com um aumento de $40\times$, equipado com uma câmera digital, resultando em um total de 316 imagens com resolução de 1920×1080 pixels. A identificação e anotação das estruturas foram realizadas manualmente por veterinários especialistas em parasitologia e patologia veterinária, que localizaram e marcaram um total de 431 macrófagos no conjunto de imagens. A Tabela 2 apresenta as estatísticas de macrófagos detectados para cada animal, incluindo o número de imagens analisadas e a quantidade total de macrófagos encontrados nessas imagens.

Tabela 2. Estatísticas de macrófagos por animal.

Animal	Nº de Imagens	Nº de Macrófagos
a2	85	124
a3	16	16
a8	12	23
a9	11	11
a10	47	87
a11	23	25
a12	71	89
a13	40	45
a14	11	11
Total	316	431

As marcações foram realizadas utilizando o CVAT (*Computer Vision Annotation Tool*) [CVAT.ai Corporation 2023], uma plataforma de código aberto amplamente utilizada para anotação de imagens e vídeos em tarefas de visão computacional. A Figura 2 apresenta exemplos de imagens capturadas e suas respectivas marcações, onde observa-se que a base de dados inclui imagens com quantidade de macrófagos variados.

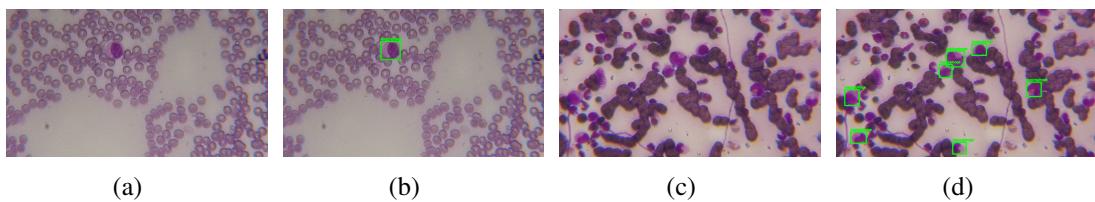


Figura 2. Exemplos de imagens capturadas e suas respectivas marcações. (a) e (c) Imagens originais, (b) e (d) Macrófagos marcados.

3.2. Detecção de Macrófagos

A detecção dos macrófagos é um passo fundamental para o diagnóstico automatizado da leishmaniose, já que as formas amastigotas do parasita geralmente se localizam em seu interior e ao redor. A detecção de macrófagos nas imagens foi realizada utilizando o

modelo *YOLOv8* (*You Only Look Once*, versão 8), uma arquitetura de rede neural convolucional projetada para detecção de objetos em tempo real. O *YOLOv8* processa a imagem inteira em uma única passagem, dividindo-a em regiões e prevendo caixas delimitadoras e probabilidades para cada objeto, o que permite identificar a localização e a classe dos objetos presentes na imagem [Redmon et al. 2015].

Para aumentar a variabilidade dos dados e melhorar a robustez do modelo, aplicamos as técnicas de aumento de dados integradas ao *YOLOv8* apresentadas na Tabela 3. Essas técnicas incluem ajustes de cores no espaço HSV (matiz, saturação e valor) e transformações geométricas, como espelhar imagem horizontal e vertical, translação, rotação, zoom e cisalhamento. Os parâmetros utilizados para aumento de dados foram definidos com base nos valores padrão recomendados pela documentação oficial do *YOLOv8* [Jocher et al. 2023], amplamente utilizados em tarefas de detecção de objetos. Essas modificações ampliam a diversidade do conjunto de treinamento sem aumentar o número de imagens armazenadas, pois são aplicadas dinamicamente a cada época do treinamento da rede, gerando variações únicas que ajudam o modelo a generalizar e reconhecer macrófagos sob diferentes condições.

Tabela 3. Aumento de dados utilizado no treinamento do YOLOv8.

Categoría	Parâmetro	Descrição
Ajuste de cores (HSV)	hsv_h	0,015 (Variação de Matiz)
	hsv_s	0,7 (Variação de Saturação)
	hsv_v	0,4 (Variação de Brilho)
Transformações geométricas	fliplr	0,5 (probabilidade de inversão horizontal)
	flipud	0,2 (probabilidade de inversão vertical)
	degrees	15 (Rotação aleatória de até ± 15 graus)
	translate	0,2 (Translação de até 20%)
	scale	0,5 (Zoom aleatório entre 50% e 150%)
	shear	10 (Cisalhamento de até ± 10 graus)
Técnicas avançadas	mosaic	1 (Mistura de 4 imagens aleatórias)
	mixup	0,2 (Sobreposição de imagens)
	copy_paste	0,1 (Copia objetos entre imagens)

3.3. Análise dos Resultados

Para avaliar o desempenho do modelo na detecção de macrófagos, foram utilizadas as métricas Precisão, Revocação (*Recall*), *F1-Score*, *mAP50* e *mAP50-95*, amplamente empregadas em modelos de detecção baseados em redes neurais convolucionais, como a *YOLOv8* [Fleiss et al. 2013, Jocher et al. 2023].

A Precisão (*Precision*) indica a proporção de detecções de macrófagos feitas pelo modelo que estavam corretas, ou seja, que correspondiam de fato a macrófagos anotados pelo especialista. A Revocação (*Recall*) mede a capacidade do modelo de encontrar todos os macrófagos presentes na imagem, refletindo quantos foram corretamente identificados em relação ao total anotado. O *F1-Score* representa a média harmônica entre precisão e revocação, sendo especialmente útil para avaliar o equilíbrio entre evitar detecções incorretas (falsos positivos) e não deixar de detectar estruturas relevantes (falsos negativos).

O *mAP@50* (*Mean Average Precision at IoU 50%*) mede a média da precisão considerando um limiar fixo de 50% de *Intersection over Union* (IoU) entre as caixas preditas e as anotações reais. No contexto da detecção de macrófagos, essa métrica avalia a capacidade do modelo de localizar corretamente essas células com base em uma sobreposição espacial mínima exigida, refletindo o alinhamento entre as predições e as anotações de referência. Por fim, o *mAP50-95* representa a média da precisão média calculada para múltiplos limiares de IoU, variando de 50% a 95%, com incrementos de 5%. Essa métrica é mais rigorosa que o *mAP50*, pois avalia a qualidade das detecções considerando diferentes níveis de sobreposição. Modelos com alto *mAP50-95* demonstram um desempenho mais robusto e generalizável, sendo mais confiáveis para aplicações reais em análise de imagens médicas.

Essas métricas oferecem uma avaliação abrangente do desempenho do modelo, permitindo analisar sua eficácia tanto na correta detecção dos macrófagos quanto na minimização de erros, validando sua confiabilidade. Com base nesses critérios, os resultados obtidos foram analisados e comparados para validar a confiabilidade do modelo proposto.

4. Resultados e Discussões

Para avaliar o método proposto para detecção automática de macrófagos, foram realizados testes preliminares dividindo o conjunto de dados em 80% (252 imagens) para treino, 10% (32 imagens) para validação e 10% (32 imagens) para teste utilizando o modelo *YOLOv8 Medium*. Durante os experimentos, foram analisados diferentes fatores que influenciam o desempenho do modelo, incluindo o tamanho das imagens, a taxa de aprendizagem e o uso do aumento de dados fornecido pelo *YOLOv8*, que não realiza aumento no número de arquivos, mas que realiza variações dinâmicas nos dados de entrada.

Os testes preliminares com diferentes tamanhos de imagem (1080×1080, 640×640 e 320×320 pixels) indicaram que tamanhos menores que 640×640 resultaram em perda significativa de precisão. A técnica de parada antecipada configurada em 20 épocas indicou que 90% dos testes encerravam antes de completar 100 épocas. Ajustar a taxa de aprendizagem de 0,01 (padrão) para 0,005 proporcionou melhorias nas métricas.

A aplicação de técnicas de aumento de dados da *YOLOv8* influenciou positivamente os resultados. A modificação dos canais de cor (HSV) melhorou o *recall* em 6,05% e o *mAP50* em 3,63%. As transformações geométricas resultaram em melhorias em todas as métricas. Por outro lado, as técnicas avançadas, quando aplicadas isoladamente, aumentaram o *mAP50* em 6,89%, mas reduziram outras métricas, como a *precision*, que apresentou queda de 2,56%. A melhor configuração foi obtida ao combinar ajustes de HSV e transformações geométricas, resultando em uma precisão de 0,825, *Recall* de 0,907, *F1-Score* de 0,864, *mAP50* de 0,866 e *mAP50-95* de 0,618 para imagens 640×640 e taxa de aprendizagem de 0,005.

A Figura 3 apresenta os gráficos da perda de localização (*train/box_loss*) e das métricas de desempenho (*precision* e *recall*) durante o treinamento do modelo *YOLOv8*. A métrica (*box_loss*) avalia o erro na posição das *bounding boxes*, e seu decaimento progressivo indica que o modelo está aprendendo a localizar melhor os macrófagos, enquanto *precision* e *recall* indicam o desempenho do modelo na detecção dos macrófagos ao longo das épocas.

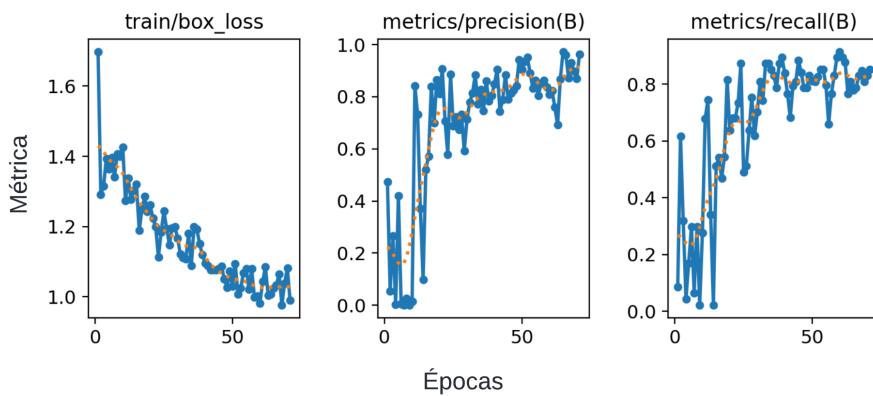


Figura 3. Evolução da Perda e Métricas de Desempenho do Modelo YOLOv8 Durante o Treinamento.

A Figura 4 apresenta exemplos de predições realizadas pelo modelo, comparando as anotações do especialista com as detecções automatizadas, incluindo as respectivas pontuações de confiança. Nas Figuras 4 (a) e (b), observa-se que o modelo identifica com precisão imagens contendo até dois macrófagos. Entretanto, na Figura 4 (c), a presença de múltiplos macrófagos na mesma imagem aumenta a complexidade da tarefa, resultando em uma diminuição na confiança das detecções. Além disso, o modelo detecta regiões não anotadas pelo especialista, indicando falsos positivos ou áreas não identificadas pelo especialista previamente. Em contexto clínico, falsos negativos podem subestimar a carga parasitária, comprometendo o diagnóstico, enquanto falsos positivos podem superestimar a presença de macrófagos, afetando a interpretação da resposta inflamatória.

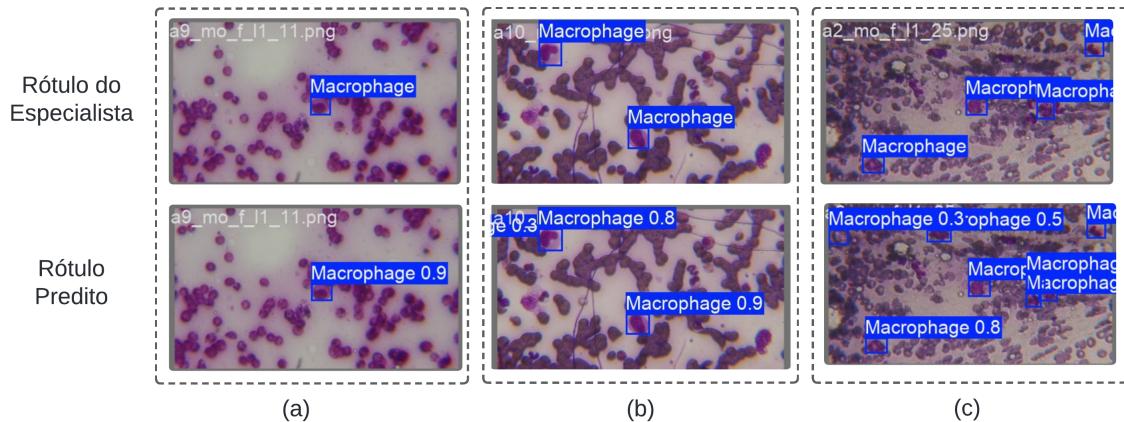


Figura 4. Resultados de predições pelo método proposto. Na linha superior estão as imagens com os rótulos do especialista, na linha inferior estão as imagens com as detecções realizadas pelo método proposto.

Diante desses resultados preliminares, optou-se por uma avaliação mais robusta utilizando validação cruzada k -fold com 5 dobras (*folds*), configuração amplamente adotada na literatura por aumentar a robustez estatística da avaliação do modelo. Em cada *fold*, os dados foram divididos em 70% para treino, 10% para validação e 20% para teste. Além disso, foi aplicada uma estratégia de aumento de dados tradicional, gerando três versões aumentadas de cada imagem original. As transformações incluíram espelhamento,

mento horizontal, ajustes de brilho e contraste, adição de ruído gaussiano, transformações geométricas, como variação de escala, rotação e cisalhamento, além de desfoque de movimento [Buslaev et al. 2020]. Esse procedimento foi conduzido a fim de comparar com a estratégia de aumento de dados da *YOLOv8*. A Tabela 4 apresenta os resultados dos experimentos realizados.

Tabela 4. Resultados da validação *k-fold* com *YOLOv8-Medium* ($LR=0,005$) considerando diferentes tamanhos de imagem e aumento de dados. Em negrito, os melhores valores de *mAP50* em cada cenário.

Tamanho	Precisão	Recall	F1	<i>mAP50</i>	<i>mAP50-95</i>
Sem Aumento de Dados					
640	$0,803 \pm 0,064$	$0,794 \pm 0,031$	$0,797 \pm 0,039$	$0,831 \pm 0,046$	$0,640 \pm 0,038$
1080	$0,782 \pm 0,047$	$0,787 \pm 0,031$	$0,782 \pm 0,013$	$0,822 \pm 0,023$	$0,639 \pm 0,019$
Com Aumento de Dados da <i>YOLOv8</i>					
640	$0,834 \pm 0,057$	$0,789 \pm 0,046$	$0,808 \pm 0,021$	$0,852 \pm 0,025$	$0,570 \pm 0,059$
1080	$0,813 \pm 0,037$	$0,796 \pm 0,055$	$0,803 \pm 0,023$	$0,850 \pm 0,037$	$0,516 \pm 0,034$
Com Aumento de Dados Tradicional					
640	$0,825 \pm 0,048$	$0,796 \pm 0,034$	$0,809 \pm 0,016$	$0,841 \pm 0,035$	$0,667 \pm 0,024$
1080	$0,815 \pm 0,042$	$0,824 \pm 0,028$	$0,819 \pm 0,025$	$0,841 \pm 0,036$	$0,625 \pm 0,027$

A configuração que obteve o maior *mAP50* (0,852) utilizou imagens de tamanho 640 com aumento de dados da *YOLOv8*. Além disso, essa configuração apresentou uma precisão de 0,834, *recall* de 0,789 e *F1-score* de 0,808. Aumentar a resolução para 1080 trouxe ganhos apenas com aumento de dados tradicional e, em alguns casos, resultou em desempenho inferior. Isso sugere que, para a detecção de macrófagos, a utilização de imagens com 640 pixels foi suficiente para alcançar desempenho similar ou superior ao de 1080 pixels, com menor tempo de treinamento.

O uso de duas técnicas de aumento de dados trouxe benefícios, aprimorando tanto a precisão quanto a capacidade de generalização do modelo. Entre elas, o aumento de dados da *YOLOv8* se mostrou mais eficaz para a métrica *mAP50*, elevando seu valor de 0,83 para 0,85. Vale destacar que esse ajuste não aumentou a quantidade de imagens no conjunto de dados, mas diversificou suas variações, proporcionando ao modelo um aprendizado mais robusto dos padrões visuais dos macrófagos.

Analizando o desvio padrão, percebe-se que os valores estão dentro de limites toleráveis (abaixo de 5% a 10% da média), garantindo consistência nos resultados. Considerando que este estudo foca na detecção de macrófagos como um primeiro passo para futuras análises das amastigotas dentro e ao redor dessas células, os resultados obtidos indicam potencial para aplicações subsequentes no diagnóstico automatizado. Para este caso, ter um *recall* e um *mAP50* acima de 80% e 75% respectivamente é essencial, pois garantir a detecção de macrófagos com confiabilidade permite avançar para a próxima etapa da pesquisa. Assim, a configuração escolhida atende ao objetivo proposto.

4.1. Comparação com o Estado da Arte

Os resultados do método proposto foram comparados com estudos da literatura previamente discutidos. Como apresentado na Tabela 5, o método proposto, obteve um *recall*

de 0,79 e um *F1-Score* de 0,81, ficando abaixo de alguns trabalhos comparados. Entretanto, é importante destacar que, quando utilizada uma divisão simples entre treino e teste, o método proposto apresentou métricas superiores às reportadas na literatura, alcançando um *recall* de 0,90 e um *F1-Score* de 0,86. Vale ressaltar que os trabalhos comparados não aplicaram validação cruzada *k-fold*, utilizando apenas uma divisão simples. Essa abordagem pode resultar em métricas com menor capacidade de generalização.

Tabela 5. Comparação do método proposto com o estado da arte.

Trabalho	Precisão	Recall	F1-Score	mAP50	mAP50-95
[Gonçalves et al. 2022]	0,94	0,64	0,76	-	-
[Górriz et al. 2018]	0,75	0,82	0,77	-	-
[Isaza-Jaimes et al. 2020]	0,78	-	-	-	-
[Neves et al. 2014]	0,81	0,87	0,84	-	-
Método Proposto	0,83	0,79	0,81	0,85	0,57

É fundamental destacar que, embora os trabalhos comparados tratem de LV em humanos e por isso apresentem metodologias e bases de dados distintas do presente estudo, a comparação foi realizada com o intuito de contextualizar os resultados obtidos. No entanto, devido às diferenças nas abordagens e nos objetivos, uma comparação direta e justa entre os estudos não é plenamente viável.

As principais limitações deste trabalho incluem a sensibilidade do modelo a variações nos dados de treinamento, o que pode estar relacionado ao fato de o conjunto de dados ser composto exclusivamente por macrófagos. Essa limitação pode ser abordada em estudos futuros ao incluir anotações de outros elementos celulares, permitindo ao modelo aprender a distinguir melhor entre diferentes classes e reduzir falsos positivos. Além disso, o conjunto de dados ainda apresenta um número limitado de imagens (316 amostras), o que mantém uma das limitações recorrentes da literatura atual, relacionada à escassez de bases públicas e abrangentes para treinamento de modelos robustos. Ademais, embora o método tenha se mostrado eficaz na detecção de macrófagos, ele não identifica diretamente as amastigotas presentes dentro e ao redor dessas células, tornando essencial o desenvolvimento de etapas futuras para aprimorar a precisão do diagnóstico automatizado da LVC.

5. Conclusão e Trabalhos Futuros

A combinação do modelo *YOLOv8* com técnicas de aumento de dados, como ajustes de cores e transformações geométricas, detecta macrófagos de forma eficiente, servindo como uma base sólida para futuras etapas no diagnóstico automatizado da LVC. Os resultados obtidos sugerem que o modelo pode ser integrado em sistemas de apoio ao diagnóstico, auxiliando especialistas na análise de amostras biológicas.

Para trabalhos futuros, pretende-se aprimorar os resultados através da utilização de novos conjuntos de dados, incluindo *datasets* que contenham múltiplas classes, como macrófagos e não-macrófagos. Isso permitirá verificar se a detecção de macrófagos torna-se mais precisa ao ensinar ao modelo a distinguir entre diferentes elementos celulares. Além disso, planeja-se aplicar técnicas de aumento de dados para expandir o número de imagens disponíveis, aumentando a variabilidade e robustez do treinamento. Por fim, será

dada continuidade ao desenvolvimento do sistema para a detecção da LVC, focando na identificação de amastigotas dentro e ao redor dos macrófagos previamente detectados, complementando o diagnóstico de forma mais abrangente.

Referências

- Álvaro, C. I. L. S. (2022). Relatório de estágio e monografia intitulada "leishmaniose canina: Sintomas e tratamentos". Master's thesis, Universidade de Coimbra (Portugal).
- Antunes, T., Godoy, K., Oliveira, G., Silveira, A., Ramos, C., and Souza, A. (2018). Técnicas de citologia aspirativa, biópsia e citobloco de medula óssea para identificação e determinação de intensidade parasitária na leishmaniose visceral canina. *Arquivo Brasileiro de Medicina Veterinária e Zootecnia*, 70:1362–1368.
- Aziz, S., Bilal, M., Khan, M. U., and Amjad, F. (2020). Deep learning-based automatic morphological classification of leukocytes using blood smears. In *2020 International Conference on Electrical, Communication, and Computer Engineering (ICECCE)*, pages 1–5. IEEE.
- Buslaev, A., Iglovikov, V. I., Khvedchenya, E., Parinov, A., Druzhinin, M., and Kalinin, A. A. (2020). Albumentations: Fast and flexible image augmentations. *Information*, 11(2):125.
- Cannet, A., Simon-Chane, C., Histace, A., Akhouni, M., Romain, O., Souchaud, M., Jacob, P., Sereno, D., Wolf, P., Dvorak, V., et al. (2023). Species identification of phlebotomine sandflies using deep learning and wing interferential pattern (wip). *Scientific Reports*, 13(1):21389.
- Coelho, M. L., França, T., Mateus, N. L. F., Junior, M. S. d. C. L., Cena, C., and do Nascimento Ramos, C. A. (2023). Canine visceral leishmaniasis diagnosis by uv spectroscopy of blood serum and machine learning algorithms. *Photodiagnosis and Photodynamic Therapy*, 42:103575.
- CVAT.ai Corporation (2023). Computer Vision Annotation Tool (CVAT).
- da Saúde, M. (2025). Painel epidemiológico. <https://www.gov.br/saude/pt-br/assuntos/saude-de-a-a-z/1/leishmaniose-visceral/>.
- Eder, K., Kutscher, T., Marzi, A., Barroso, Á., Schnekenburger, J., and Kemper, B. (2021). Automated detection of macrophages in quantitative phase images by deep learning using a mask region-based convolutional neural network. In *Label-free Biomedical Imaging and Sensing (LBIS) 2021*, volume 11655, pages 88–94. SPIE.
- Fleiss, J. L., Levin, B., and Paik, M. C. (2013). *Statistical methods for rates and proportions*. john wiley & sons.
- Gonçalves, C., Andrade, A. L., Dias, V. B. L., de Andrade, N. B., Aguiar, B. G. A., Veloso, R. R., et al. (2022). Método automático para detecção de leishmaniose visceral em humanos. In *Congresso Brasileiro de Automática-CBA*, volume 3.
- Gonçalves, C., Andrade, N., Borges, A., Rodrigues, A., Veras, R., Aguiar, B., and Silva, R. (2023). Automatic detection of visceral leishmaniasis in humans using deep learning. *Signal, Image and Video Processing*, 17(7):3595–3601.

- Górriz, M., Aparicio, A., Raventós, B., Vilaplana, V., Sayrol, E., and López-Codina, D. (2018). Leishmaniasis parasite segmentation and classification using deep learning. In *Articulated Motion and Deformable Objects: 10th International Conference, AMDO 2018, Palma de Mallorca, Spain, July 12-13, 2018, Proceedings 10*, pages 53–62. Springer.
- Isaza-Jaimes, A., Bermúdez, V., Bravo, A., Castrillo, J. S., Lalinde, J. D. H., Fossi, C. A., Flórez, A., and Rodríguez, J. E. (2020). A computational approach for leishmania genus protozoa detection in bone marrow samples from patients with visceral leishmaniasis. *AVFT–Archivos Venezolanos de Farmacología y Terapéutica*, 39(7).
- Jocher, G., Chaurasia, A., and Qiu, J. (2023). Ultralytics yolov8.
- Koutinas, A. and Koutinas, C. (2014). Pathologic mechanisms underlying the clinical findings in canine leishmaniosis due to leishmania infantum/chagasi. *Veterinary pathology*, 51(2):527–538.
- Kumar, R. and Nylén, S. (2012). Immunobiology of visceral leishmaniasis. *Frontiers in immunology*, 3:251.
- Larios, G., Ribeiro, M., Arruda, C., Oliveira, S. L., Canassa, T., Baker, M. J., Marangoni, B., Ramos, C., and Cena, C. (2021). A new strategy for canine visceral leishmaniasis diagnosis based on ftir spectroscopy and machine learning. *Journal of Biophotonics*, 14(11):e202100141.
- Marcondes, M. and Day, M. J. (2019). Current status and management of canine leishmaniasis in latin america. *Research in Veterinary Science*, 123:261–272.
- Neves, J. C., Castro, H., Tomás, A., Coimbra, M., and Proença, H. (2014). Detection and separation of overlapping cells based on contour concavity for leishmania images. *Cytometry Part A*, 85(6):491–500.
- PAHO (2017). *Epidemiological Report of the Americas. Leishmaniasis*. PAHO Washington, DC, USA.
- Redmon, J., Divvala, S., Girshick, R., and Farhadi, A. (2015). You only look once: Unified, real-time object detection. *arXiv preprint arXiv:1506.02640*.
- Sadeghi, A., Sadeghi, M., Fakhar, M., Zakariaei, Z., Sadeghi, M., and Bastani, R. (2024). A deep learning-based model for detecting leishmania amastigotes in microscopic slides: a new approach to telemedicine. *BMC Infectious Diseases*, 24(1):551.
- Silva, F. S. (2007). Patologia e patogênese da leishmaniose visceral canina. *Rev Trop Cienc Agr Biol*, 1(1):20–31.
- Silva, J. M., Zacarias, D. A., Figueirêdo, L. C. D., Soares, M. R. A., Ishikawa, E. A., Costa, D. L., and Costa, C. H. (2014). Bone marrow parasite burden among patients with new world kala-azar is associated with disease severity. *American Journal of Tropical Medicine and Hygiene*, 90:621–626.