

Viviane Barbosa Leal Dias

Orientador: Romuere Rodrigues Veloso e Silva

Co-orientadora: Ana Carolina Landim Pacheco

Classificação Automática de Macrófagos com Visão Computacional para Apoio ao Diagnóstico da Leishmaniose Visceral Canina

Picos - PI

13 de junho de 2025

Viviane Barbosa Leal Dias

Orientador: Romuere Rodrigues Veloso e Silva

Co-orientadora: Ana Carolina Landim Pacheco

Classificação Automática de Macrófagos com Visão Computacional para Apoio ao Diagnóstico da Leishmaniose Visceral Canina

Trabalho de Conclusão de Curso em Bacharelado em Sistemas de Informação na Universidade Federal do Piauí. Este modelo está em conformidade com as normas ABNT.

Universidade Federal do Piauí
Campus Senador Helvídio Nunes de Barros
Bacharelado em Sistemas de Informação

Picos - PI
13 de junho de 2025

FICHA CATALOGRÁFICA
Serviço de Processamento Técnico da Universidade Federal do Piauí
Biblioteca José Albano de Macêdo

D541c Dias, Viviane Barbosa Leal.

Classificação automática de macrófagos com visão computacional para apoio ao diagnóstico da leishmaniose visceral canina / Viviane Barbosa Leal Dias – 2025.

37 f.

1 Arquivo em PDF

Indexado no catálogo *online* da biblioteca José Albano de Macêdo-CSHNB
Aberto a pesquisadores, com restrições da Biblioteca

Trabalho de Conclusão de Curso (Graduação) – Universidade Federal do Piauí, Curso de Bacharelado em Sistemas de Informação, Picos, 2025.

“Orientador: Romuere Rodrigues Veloso e Silva”

“Co-orientadora: Ana Carolina Landim Pacheco”

1. Sistemas automatizados. 2. Base de dados. 3. Classificação automática de doenças. I. Dias, Viviane Barbosa Leal. II. Pacheco, Ana Carolina Landim. III. Título.

CDD 005

Elaborada por Maria Letícia Cristina Alcântara Gomes
Bibliotecária CRB nº 03/1835

CLASSIFICAÇÃO AUTOMÁTICA DE MACRÓFAGOS COM VISÃO
COMPUTACIONAL PARA APOIO AO DIAGNÓSTICO DA LEISHMANIOSE
VISCERAL CANINA

VIVIANE BARBOSA LEAL DIAS

Monografia aprovada como exigência parcial para obtenção do grau de Bacharel em Sistemas
de Informação.

Data de Aprovação

Picos – PI, 23 de junho de 2025

Prof. Romuere Rodrigues Veloso e Silva

Prof. Clésio de Araújo Gonçalves

Prof. Rafael Luz de Araújo

Agradecimentos

De repente, a escrita — que sempre me foi fácil e despreziosa — falhou assim que me deparei com a necessidade de escrever este agradecimento. Como eu poderia explicar em palavras sobre tudo o que fui grata ao longo desses anos? Resta-me tentar.

À minha família, obrigada pelo apoio incondicional mesmo sem entender como qualquer coisa do mundo era menos importante do que esse curso cujo nunca entenderam direito o que significa. Aproveito para também pedir desculpas pela minha ausência em todo e qualquer evento ou tentativa de confraternização ao longo destes anos. Ao meu namorado, obrigada por todo o cuidado, apoio, paciência e incentivo. Obrigada por transformar longas noites de estresse em momentos tranquilos e acolhedores, por lembrar-me de cuidar da saúde, por me fazer desacelerar e por mostrar que a vida acontece agora.

Aos amigos que fiz ao longo desta caminhada, o meu muito obrigada por sempre estarem dispostos a dividir a dificuldade, as noites sem dormir, os trabalhos quase intermináveis, as frustrações, as dúvidas e principalmente, toda a diversão que nos restava com nossos poucos neurônios funcionando. Em memória da minha amiga Isa Mel, com quem tive o privilégio de iniciar esta trajetória e que partiu antes que pudéssemos cruzar juntas a linha de chegada. Sua presença, no entanto, permanece viva em mim — nas lembranças, nas conquistas e neste trabalho, que, de muitas formas, também é dela.

Ao meu orientador, professor Romuere, agradeço pelos ensinamentos, pela generosidade em compartilhar sua experiência profissional, e por ter sido uma presença constante e inspiradora ao longo desta caminhada. Sou especialmente grata por me ajudar a superar o medo de falar em público, por sempre me apresentar novos desafios e por sua compreensão em cada etapa do processo. Muito do que conquistei até aqui devo à sua orientação. Espero, um dia, alcançar o mesmo nível de excelência profissional que o senhor representa.

À minha coorientadora, professora Carol, minha sincera gratidão por cada lição, pela paciência e por compartilhar tanto do seu conhecimento com generosidade. Sua dedicação foi essencial para o meu crescimento ao longo dessa jornada. À professora Juliana, obrigada por cada conversa cheia de histórias, reflexões e aprendizados, e por transformar cada encontro em uma aula de vida. Sua paixão por ensinar me inspirou profundamente, e levo comigo, além do conhecimento, a amizade construída ao longo do caminho.

Ao corpo docente do curso de Sistemas de Informação, muito obrigada. Sei que, ao longo desses anos, cada professor deu o seu melhor para formar profissionais qualificados. Chego realizada por ter aprendido e compartilhado ideias com pessoas de tamanha sabedoria; é gratificante saber que cada um faz parte da minha história.

Por fim, agradeço à vida por me conduzir a uma trajetória na qual encontrei sentido e realização profissional. Que venha o futuro!

Este trabalho é dedicado às crianças adultas que, quando pequenas, sonharam em se tornar cientistas.

Autor desconhecido

Resumo

A Leishmaniose Visceral é uma doença tropical negligenciada que impacta significativamente a saúde pública. Estima-se que entre 50.000 e 90.000 novos casos ocorram anualmente em todo o mundo, dos quais apenas 25% a 45% são oficialmente notificados à Organização Mundial da Saúde. Ela é transmitida através de flebotômios, e o cão é o principal reservatório do parasita. O diagnóstico padrão-ouro da Leishmaniose Visceral baseia-se na análise direta por microscopia, na qual o profissional busca a presença do parasita em lâminas obtidas por aspirado de medula óssea, um procedimento que demanda profissionais especializados, caracteriza-se por sua exaustividade e prolongada duração, e envolve um grande volume de dados a ser analisado, fatores que podem tornar o processo suscetível a falhas e erros humanos. Neste contexto, o presente trabalho propõe o desenvolvimento de um sistema automatizado para a detecção e classificação de macrófagos infectados por *Leishmania* em imagens microscópicas da medula óssea canina, por meio da aplicação de técnicas de Visão Computacional e aprendizado profundo. Para tanto, foi construída uma base de dados composta por imagens anotadas por especialistas. Técnicas de pré-processamento, aumento de dados e transferência de aprendizado foram aplicadas em diferentes arquiteturas de Redes Neurais Convolucionais. A avaliação dos modelos foi realizada com base nas métricas de Acurácia, Precisão, *Recall*, *F1-Score* e Coeficiente *Kappa*, destacando-se o desempenho da arquitetura ResNet50, que obteve 99% de Precisão. Os resultados evidenciam o potencial da ferramenta para auxiliar no diagnóstico laboratorial da Leishmaniose Visceral canina, auxiliando na detecção precoce e contribuindo para o controle da enfermidade.

Palavras-chaves: Leishmaniose Visceral. Aprendizado profundo. Classificação.

Abstract

Visceral leishmaniasis is a neglected tropical disease that significantly impacts public health. It is estimated that between 50,000 and 90,000 new cases occur annually worldwide, of which only 25% to 45% are officially reported to the World Health Organization. It is transmitted by sand flies, and dogs are the main reservoir of the parasite. The gold standard diagnosis of visceral leishmaniasis is based on direct analysis by microscopy, in which the professional looks for the presence of the parasite in slides obtained by bone marrow aspirate, a procedure that requires specialized professionals, is characterized by its exhaustiveness and prolonged duration, and involves a large volume of data to be analyzed, factors that can make the process susceptible to failures and human errors. In this context, this work proposes the development of an automated system for the detection and classification of macrophages infected by *Leishmania* in microscopic images of canine bone marrow, through the application of Computer Vision and deep learning techniques. For this purpose, a database composed of images annotated by experts was built. Preprocessing, data augmentation and transfer learning techniques were applied in different Convolutional Neural Network architectures. The evaluation of the models was performed based on the metrics of Accuracy, Precision, Recall, F1-Score and Kappa Coefficient, highlighting the performance of the ResNet50 architecture, which obtained 99% Accuracy. The results highlight the potential of the tool to assist in the laboratory diagnosis of canine Visceral Leishmaniasis, aiding in early detection and contributing to the control of the disease.

Lista de ilustrações

Figura 1 – Meta e taxa de letalidade por LV, Brasil, Paraguai, República Bolivariana da Venezuela e Região das Américas, 2017-2022. Fonte: (SAÚDE, 2023).	18
Figura 2 – Coleta de amostra da medula óssea em cães. Fonte: (LARAIA; SANTANA; DONATO, 2018)	18
Figura 3 – Imagem microscópica de aspirado de medula óssea canina evidenciando a presença de formas amastigotas de Leishmania (destacadas em vermelho). Observa-se uma maior concentração de amastigotas no interior de um macrófago (demarcado em verde), reforçando o papel dessas células como principais hospedeiras do parasita no diagnóstico parasitológico da Leishmaniose Visceral. Fonte: Autoria própria.	19
Figura 4 – Etapas do processo de VC adotado nesta pesquisa. Fonte: Autoria própria.	20
Figura 5 – Fluxograma da metodologia proposta para o desenvolvimento deste trabalho. Fonte: Autoria própria.	25
Figura 6 – Etapas da aquisição e anotação de dados. Fonte: Autoria própria. . . .	26
Figura 7 – Estruturas classificadas como macrófagos. Fonte: Autoria própria. . . .	27
Figura 8 – Estruturas classificadas como não-macrófagos. Fonte: Autoria própria. .	27
Figura 9 – Exemplo de aumento nos dados. Fonte: Autoria própria.	28
Figura 10 –As imagens a), b), c), d), e e) são imagens que foram classificadas erroneamente pela rede como não pertencentes à classe de macrófagos, embora correspondam a macrófagos. Fonte: Autoria própria.	31
Figura 11 –As imagens a), b), c), d), e) e f) são imagens de não-macrófagos corretamente classificadas pela rede. Fonte: Autoria própria.	31

Lista de tabelas

Tabela 1 – Tabela de Trabalhos Relacionados	22
Tabela 2 – Informações de parâmetros sobre as CNNs utilizadas durante este trabalho.	28
Tabela 3 – Resultados obtidos através da CNN e com a aplicação do <i>fine-tuning</i> . .	30
Tabela 4 – Comparação das métricas dos trabalhos relacionados com este estudo. .	30

Lista de abreviaturas e siglas

VC	Visão Computacional
LV	Leishmaniose Visceral
CNN	Convolutional Neural Network (Rede Neural Convolutacional)
IA	Inteligência Artificial
IoU	Intersection over Union (Índice de Sobreposição)
RGB	Red Green Blue (Modelo de cor)
TP	True Positive (Verdadeiro Positivo)
TN	True Negative (Verdadeiro Negativo)
FP	False Positive (Falso Positivo)
FN	False Negative (Falso Negativo)

Lista de símbolos

κ	Coeficiente <i>Kappa</i> de Cohen (índice de concordância)
\times	Multiplicação (usado para indicar aumento de zoom ou magnificação)
μm	Micrômetro (unidade de medida de comprimento)

Sumário

1	Introdução	13
1.1	Objetivos	14
1.2	Publicações	14
1.3	Organização do Trabalho	16
2	Referencial Teórico	17
2.1	Epidemiologia e Letalidade da Leishmaniose Visceral	17
2.2	Diagnóstico Parasitológico	18
2.3	Visão Computacional	19
2.4	Classificação	20
2.5	Métricas de Desempenho	21
3	Trabalhos Relacionados	22
4	Metodologia	25
4.1	Aquisição de Dados	25
4.2	Pré-processamento	26
4.3	Aumento de Dados	26
4.4	Classificação de Imagens	28
4.5	Avaliação de Desempenho	29
5	Resultados	30
5.1	Discussão dos Resultados e Limitações	31
6	Conclusão	33
	Referências	34

1 Introdução

A leishmaniose é uma doença tropical negligenciada distribuída globalmente, com mais de 12 milhões de pessoas infectadas ([Organização Pan-Americana da Saúde, 2024](#)). Ela é causada por um protozoário do gênero *Leishmania*, e tem um impacto significativo na saúde pública, pois não recebe a atenção adequada para sua prevenção. A leishmaniose é transmitida através da picada de insetos conhecidos como flebotomíneos. O cão é o principal intermediário desta enfermidade ([CAMPINO; MAIA, 2010](#)), e na dinâmica de transmissão atua como reservatório no ciclo de propagação do parasita aos humanos. A forma mais severa da doença é a Leishmaniose Visceral (LV) ([GONÇALVES et al., 2022](#)) e se não for tratada, pode se tornar fatal em até 95% dos casos ([Pan American Health Organization, 2022](#)). Estima-se que, a cada ano, surgem cerca de 1.000.000 novos casos de LV em humanos, e que apenas 25% a 45% desses casos são oficialmente notificados ([World Health Organization, 2023](#)), o que destaca a gravidade do problema.

Em cães, a LV apresenta uma ampla variação clínica, que se manifesta de formas sintomáticas leves à severas, ou até formas assintomáticas ([IVĂNESCU et al., 2023](#)). Os sintomas clínicos estão ligados à composição genética, estado nutricional, carga parasitária inoculada e resposta imunológica inerentes a cada animal, o que pode ter um impacto direto na sua vulnerabilidade ou resistência à infecção ([BANETH, 2006](#)). A doença se expande pelo organismo do paciente através da circulação sanguínea e linfática, resultando na infecção de várias células em órgãos distintos, como a medula óssea, o baço, o fígado e os gânglios linfáticos ([ÁLVARO, 2022](#)). Em humanos, os sintomas incluem febre de longa duração, fraqueza, e perda de apetite ([KUMAR; NYLÉN, 2012](#)). Na ausência de um tratamento adequado é possível que a doença progrida e seja fatal para o paciente, seja ele humano ou animal. Por isso, é essencial a detecção precoce e o tratamento em cães para controlar a disseminação da doença e diminuir sua incidência na população humana.

O diagnóstico da leishmaniose é um desafio singular para cada paciente, baseado na sua história, nos sintomas observados na avaliação clínica e nos resultados laboratoriais obtidos ([THAKUR; JOSHI; KAUR, 2020](#); [SANTOS et al., 2021](#)). O método padrão-ouro para o diagnóstico, válido tanto para humanos quanto para cães, é a análise parasitológica direta através de exames de microscopia óptica. Esta análise consiste na busca por parasitas em amostras de esfregaços e aspirados obtidos de órgãos como o baço, fígado, medula óssea e gânglios linfáticos ([PINELLI et al., 1994](#); [BARBIERI, 2006](#)). A avaliação desses dados pode ser demorada e exaustiva para os profissionais de saúde ([SILVA et al., 2019](#)), devido ao alto volume e à necessidade de análise minuciosa, que requer atenção prolongada, precisão e especialização do profissional, durante horas consecutivas.

O uso de técnicas avançadas de aprendizado de máquina durante o processamento e a avaliação de imagens médicas podem auxiliar na automação do diagnóstico de doenças

(SILVA et al., 2016). Para reduzir o esforço em tarefas repetitivas e alcançar eficiência durante o processo de análise laboratorial, a aplicação de métodos computacionais surge como uma alternativa para a automação do diagnóstico da LV. Dentre as diversas abordagens disponíveis, destaca-se a aplicação das técnicas de Visão Computacional (VC), que desempenham um papel significativo na detecção de doenças parasitológicas, com ênfase na LV (GONÇALVES et al., 2023b). Essas técnicas demonstram precisão notável, e surgem como uma proposta para acelerar a identificação precoce de pacientes afetados. O desenvolvimento e a aplicação dessas técnicas são necessários para melhorar os serviços de saúde e promover melhores resultados no tratamento de indivíduos afetados por LV.

1.1 Objetivos

O objetivo geral deste projeto é desenvolver uma ferramenta para classificar macrófagos através do uso de imagens microscópicas no exame parasitológico direto da LV. Essa ferramenta visa automatizar e facilitar o processo do diagnóstico, reduzindo o tempo de busca por parasitas e auxiliando na realização da identificação precoce da doença. Para atingir esse objetivo geral, foram estabelecidos os seguintes objetivos específicos:

- Criar uma base de dados através da captura de imagens microscópicas do esfregaço de medula óssea. A base deve conter imagens positivas e negativas de LV.
- Desenvolver um sistema de VC para realizar a classificação de macrófagos para auxiliar no diagnóstico da LV canina.
- Avaliar a eficácia e precisão da metodologia proposta.

1.2 Publicações

- Machine Learning no Diagnóstico Parasitológico Direto de Leishmaniose Visceral: Uma Revisão **Viviane B. L. Dias**, Clara E. S. Sátiro, Armando L. Borges, Kawan S. Dias, Rafael L. Araújo, Lucas B. M. de Souza, Clésio de A. Gonçalves, Ana Carolina L. Pacheco, Romuere R. V. e Silva *Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS), 2025*
- Detecção Automática de Leishmaniose Visceral Canina Utilizando Deep Learning **VBL Dias**, AL Borges, C Gonçalves, AC Landim, DA Viana, RRV Silva *Revista de Sistemas e Computação-RSC, 2024*
- Detecção de Leishmaniose Visceral em Humanos Utilizando Redes Neurais **VBL Dias**, AL Borges, C de Araujo Gonçalves, ACL Pacheco, RR Veloso *Encontro Unificado de Computação do Piauí (ENUCOMPI), 2023*

- Detecção Automática de Macrófagos em Esfregaço de Medula Óssea Canina com Deep Learning Rafael Luz Araújo, **Viviane B. L. Dias**, Armando Luz Borges, Lucas B. M. de Souza, Kawan Sousa Dias, Clara E. S. Sátiro, Clésio de A. Gonçalves, Ana C. L. Pacheco, Romuere R. V. e Silva *Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS), 2025*
- Sistema WEB para Diagnóstico Automatizado por Imagem com Suporte a Diferentes Modelos de Classificação Microscópica Lucas B. M. de Souza, Kawan S. Dias, Armando L. Borges, **Viviane B. L. Dias**, Clésio de A. Gonçalves, Rafael L. Araújo, Clara E. S. Sátiro, Ana Carolina L. Pacheco, Romuere R. V. e Silva *Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS), 2025*
- Sistema WEB para classificação de Leishmaniose Visceral com coleta de imagem microscópicas automática Lucas BM de Sousa, Armando L Borges, **Viviane BL Dias**, Clésio de A Gonçalves, Daniel de A Viana, Ana Carolina L Pacheco, Romuere RV *Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS), 2024*
- Detecção Automática de Macrófagos em Exame Parasitológico Utilizando Clustering e Redes Neurais Convolucionais Armando L Borges, **Viviane BL Dias**, Clésio de A Gonçalves, Lucas BM de Sousa, Daniel de A Viana, Ana Carolina L Pacheco, Romuere RV *Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS), 2024*
- Explorando a Explicabilidade da Inteligência Artificial-Técnicas para Compreender e Interpretar Modelos de Aprendizado de Máquina Júlio VM Marques, Clésio A Gonçalves, Pablo de Abreu Vieira, Armando L Borges, **Viviane B Leal Dias**, Willians S Santos, Romuere RV Silva *Sociedade Brasileira de Computação, 2023*
- Detection of human visceral leishmaniasis parasites in microscopy images from bone marrow parasitological examination C Gonçalves, A Borges, **V Dias**, J Marques, B Aguiar, C Costa, R Silva *Applied Sciences, 2023*
- Método automático para detecção de Leishmaniose Visceral em humanos Clésio de Araújo Gonçalves, Armando Luz Borges, **Viviane Barbosa Leal Dias**, Nathália Batista de Andrade, Bruno Guedes Alcoforado Aguiar, Romuere Rodrigues Veloso *Congresso Brasileiro de Automática-CBA, 2022*
- Visceral Leishmaniasis Detection Using Deep Learning Techniques and Multiple Color Space Bands AL Borges, CA Gonçalves, **VBL Dias**, EA Sousa, CHN Costa, RRV Silva *International Conference on Intelligent Systems Design and Applications, 2022*

1.3 Organização do Trabalho

Este trabalho está organizado em seis seções principais. A Seção 2 compõe o referencial teórico, abordando os principais conceitos relacionados à LV, diagnóstico parasitológico, técnicas de VC, métodos de classificação e métricas de desempenho. A Seção 3 apresenta os trabalhos relacionados, destacando abordagens anteriores voltadas à detecção da doença. Na Seção 4, descreve-se a metodologia adotada, incluindo as etapas de aquisição, pré-processamento e aumento de dados, além da classificação de imagens e da avaliação de desempenho dos modelos. A Seção 5 apresenta os resultados obtidos, seguidos da análise crítica na subseção de discussão e limitações. Por fim, a Seção 6 traz as conclusões do estudo, destacando as contribuições alcançadas e apontando direções para investigações futuras.

2 Referencial Teórico

O diagnóstico da LV demanda a realização de testes em laboratórios especializados (SUNDAR; RAI, 2002). Em todo o mundo, especialmente em regiões endêmicas e com recursos limitados, os laboratórios frequentemente empregam métodos de detecção como microscopia, histologia, cultura e sorologia (REITHINGER; DUJARDIN, 2007). Este estudo se concentra especificamente no diagnóstico por microscopia, que é o método padrão-ouro para o diagnóstico, e evidencia um notável potencial para automação, particularmente por meio da implementação de métodos baseados em VC. Tais métodos são concebidos para aprimorar o processo diagnóstico (LEBEDEV *et al.*, 2018), promovendo a precisão e eficiência na identificação dos parasitas responsáveis pela LV. O objetivo desta seção consiste em fornecer uma análise detalhada da epidemiologia da doença, e da microscopia como técnica de detecção de parasitas no diagnóstico da LV, além de explorar o uso de técnicas de VC para uma identificação precisa desta patologia.

2.1 Epidemiologia e Letalidade da Leishmaniose Visceral

A LV representa um relevante problema de saúde pública nas Américas, com destaque para o Brasil, que se configura como o principal epicentro da doença na região. Dados epidemiológicos apontam que, em 2022, o país foi responsável por aproximadamente 92% dos casos notificados de LV entre os oito países das Américas que registraram a enfermidade, incluindo Argentina, Estado Plurinacional da Bolívia, Colômbia, Guatemala, Paraguai, Uruguai e República Bolivariana da Venezuela (SAÚDE, 2023). Desses casos, 88% foram confirmados por métodos laboratoriais, enquanto os 12% restantes receberam o diagnóstico baseado em critérios clínico-epidemiológicos, o que evidencia a importância da ampliação do acesso a métodos diagnósticos padronizados para o controle da doença.

No que se refere à letalidade, Brasil e Paraguai apresentam os maiores índices da região. Especificamente no Brasil, a taxa de letalidade por LV, que já era a mais elevada entre os países das Américas em 2017, alcançou 9,8% em 2022, representando um aumento de 27% em relação ao ano anterior, conforme apresenta a Figura 1. Além disso, o Brasil concentra o maior número absoluto de óbitos decorrentes da doença, o que reforça a necessidade urgente de implementação de estratégias mais eficazes de prevenção, diagnóstico precoce e manejo clínico, com vistas à redução da mortalidade associada à LV.

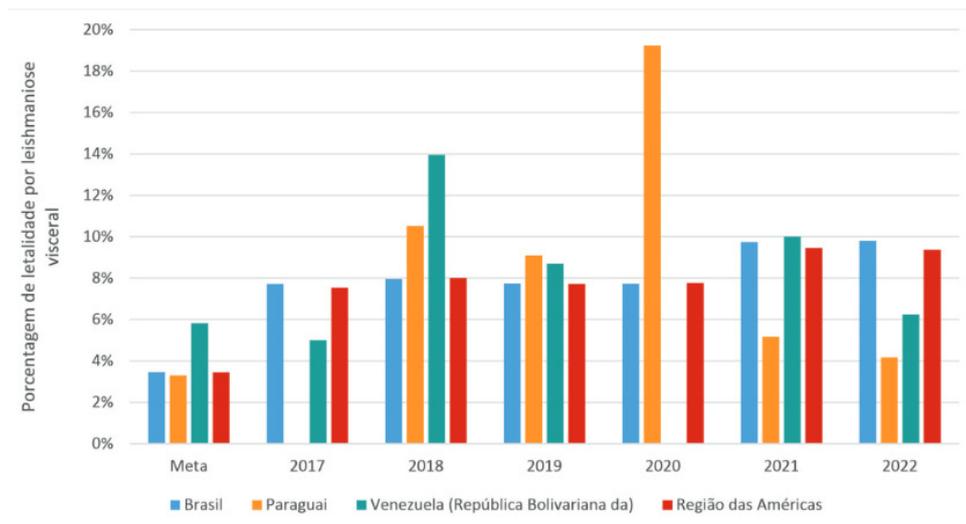


Figura 1 – Meta e taxa de letalidade por LV, Brasil, Paraguai, República Bolivariana da Venezuela e Região das Américas, 2017-2022. Fonte: (SAÚDE, 2023).

2.2 Diagnóstico Parasitológico

O diagnóstico parasitológico direto é considerado o método padrão-ouro para a detecção da *Leishmania* e, conseqüentemente, da LV (SRIVIDYA et al., 2012). Essa técnica destaca-se pela alta especificidade, que pode alcançar até 100%, uma vez que raramente classifica erroneamente indivíduos não infectados como positivos. No entanto, sua sensibilidade é variável, principalmente devido à distribuição heterogênea do parasita nos tecidos (GONTIJO; MELO, 2004), o que pode comprometer a detecção em alguns casos positivos. O exame consiste na coleta de material biológico proveniente de órgãos ou tecidos suspeitos de infecção, como pele, linfonodos, medula óssea, baço e, em menor escala, fígado (FARIA; ANDRADE, 2012). Dentre esses, os aspirados de medula óssea e linfonodos são os métodos mais utilizados na prática veterinária para o diagnóstico da LV canina (SILVA, 2007). A Figura 2 apresenta o procedimento da coleta de amostra através da medula óssea. Após a realização da coleta, a amostra é depositada em uma lâmina de vidro, submetida a coloração específica e, em seguida, analisada ao microscópio.



Figura 2 – Coleta de amostra da medula óssea em cães. Fonte: (LARAIA; SANTANA; DONATO, 2018)

Durante a análise microscópica, o profissional de saúde busca identificar formas amastigotas do parasita, que representam a fase intracelular da *Leishmania* (SAKKAS; GARTZONIKA; LEVIDIOTOU, 2016). Essas formas são geralmente observadas no interior de macrófagos, células que atuam como principais hospedeiras do parasita, embora também possam estar presentes, em menor número, fora dessas células (SUNDAR; SINGH, 2018), conforme ilustrado na Figura 3. Apesar da robustez do método, sua eficácia está fortemente condicionada à habilidade do profissional envolvido tanto na coleta quanto na leitura citopatológica da lâmina, além de fatores como carga parasitária e a resposta imune do hospedeiro (SOLANO-GALLEGO et al., 2000). A identificação das amastigotas é uma tarefa desafiadora, considerando seu pequeno tamanho, variando de $1.5\ \mu\text{m}$ a $3\ \mu\text{m} \times 3\ \mu\text{m}$ a $6.5\ \mu\text{m}$, e sua semelhança com outras estruturas celulares (RODRIGUEZ et al., 2019; SILVA et al., 2014), o que pode dificultar o diagnóstico.

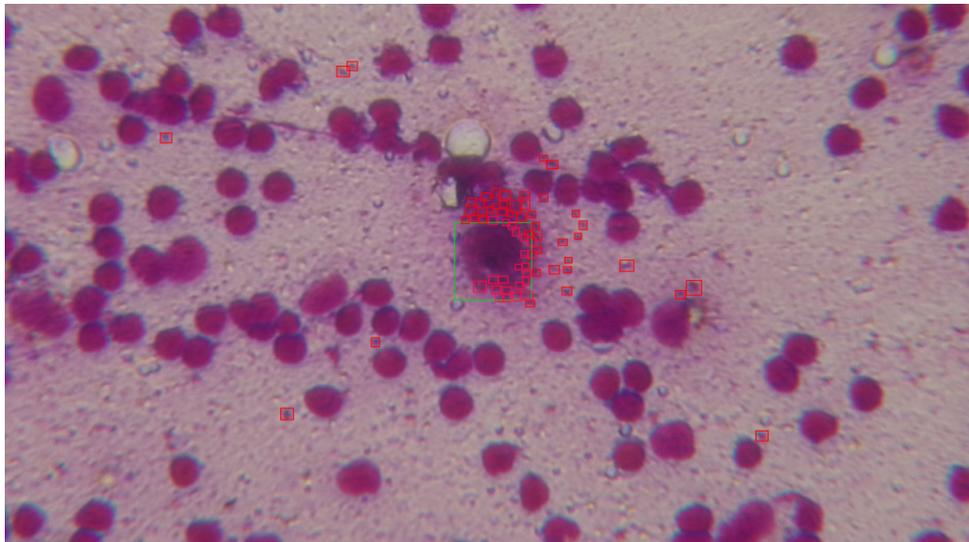


Figura 3 – Imagem microscópica de aspirado de medula óssea canina evidenciando a presença de formas amastigotas de *Leishmania* (destacadas em vermelho). Observa-se uma maior concentração de amastigotas no interior de um macrófago (demarcado em verde), reforçando o papel dessas células como principais hospedeiras do parasita no diagnóstico parasitológico da Leishmaniose Visceral. Fonte: Autoria própria.

2.3 Visão Computacional

A VC emerge como um campo significativo da Inteligência Artificial (IA), e tem um destaque notável em sua aplicação na área médica (CHEN, 2016). Seu foco reside em estudar e analisar métodos que proporcionem às máquinas a capacidade de visualizar e aprender, emulando o processo de modelagem e reprodução da visão humana. Essa área de estudo visa equipar as máquinas com a capacidade de compreender e interpretar informações a partir de dados visuais, incluindo dados multidimensionais, por meio da análise de imagens (PARKER, 2010). Ao ser aplicada, a VC se revela como um método

transformador na medicina, permitindo o diagnóstico precoce e preciso de doenças, o desenvolvimento de novos tratamentos e a elevação da qualidade de vida dos pacientes.

Os sistemas de VC são reconhecidos por sua característica distintiva de ter uma ou mais imagens como entrada e gerar informações correspondentes como saída (ZHANG, 2010). Geralmente, esses sistemas computacionais são notáveis pela simplicidade de usabilidade, demandando apenas as informações de entrada e retornando a saída (SALAZAR et al., 2019). Nesse caso, a entrada consiste em imagens microscópicas de lâminas, e a saída consiste no diagnóstico realizado, juntamente com os campos que contribuíram para o auxílio ao diagnóstico obtido. Este método permite ao profissional de saúde analisar e validar o diagnóstico fornecido pelo sistema (SHORTLIFFE; CIMINO, 2014). O desenvolvimento do sistema de VC é geralmente dividido em várias etapas (NIXON; AGUADO, 2019), neste trabalho as etapas são: coleta de imagens, pré-processamento, e classificação, como mostra a Figura 4. Após a classificação das imagens, é feita a verificação dos resultados da pesquisa e a análise de confiabilidade da solução proposta (SCHERER, 2020).

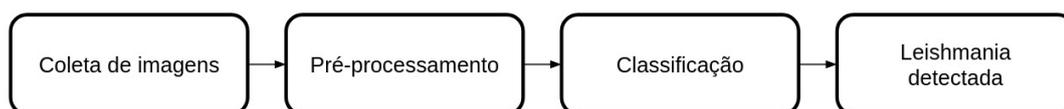


Figura 4 – Etapas do processo de VC adotado nesta pesquisa. Fonte: Autoria própria.

2.4 Classificação

A classificação de imagens é um procedimento em que uma imagem de entrada é atribuída a uma categoria específica ou a probabilidade de pertencer a uma classe determinada (MASSUCATTO, 2018). Para os seres humanos, a atividade de classificar imagens é habitualmente considerada simples e é uma habilidade básica adquirida desde cedo, mantendo-se desenvolvida mesmo na idade adulta. Essa capacidade possibilita que o indivíduo consiga identificar e classificar imagens ou objetos de forma intuitiva. Quando um computador processa uma imagem, ele a interpreta como uma grade de *pixels* com valores geralmente distribuídos entre 0 e 255. Se a imagem for colorida e estiver representada no modelo RGB, tem três camadas para os canais de cor. Para uma Rede Neural Convolutiva (CNN), cada imagem é tratada como um *array* multidimensional de ordem 3 se a imagem for colorida, e ordem 2 se a imagem estiver em escala de cinza (WU, 2017).

Dentro de uma arquitetura CNN, a imagem de entrada é submetida a uma série de processamentos, representados por diferentes camadas, com o objetivo de produzir uma saída que possa ser utilizada para a classificação da imagem. Essas camadas desempenham funções específicas e são compostas por várias formas, sendo as mais básicas as camadas de convolução, as camadas de agrupamento (*pooling*) e as camadas totalmente conectadas. As fases iniciais de uma CNN, que compreendem suas primeiras camadas de

convolução e *pooling*, são amplamente reconhecidas como as mais essenciais dentro da arquitetura da rede. Essas etapas assumem uma importância primordial no processamento computacional, sendo responsáveis pela maior parcela dele (BRANDÃO et al., 2005).

2.5 Métricas de Desempenho

A Acurácia é uma métrica utilizada na avaliação de modelos de classificação, pois representa a proporção de predições corretas em relação ao total de instâncias avaliadas. Embora forneça uma visão geral da performance do modelo, sua aplicação em conjuntos de dados desbalanceados pode ser limitada, uma vez que tende a favorecer a classe majoritária, resultando em uma avaliação otimista (POWERS, 2011; HE; GARCIA, 2009).

$$\text{Acurácia} = \frac{TP + TN}{TP + TN + FP + FN}. \quad (2.1)$$

A Precisão refere-se à proporção de instâncias positivas corretamente classificadas entre todas as classificações positivas realizadas pelo modelo. Essa métrica é relevante em contextos nos quais os falsos positivos representam um risco elevado, como em diagnósticos médicos. No entanto, quando analisada isoladamente, pode não refletir a sensibilidade do modelo frente às instâncias positivas reais (SOKOLOVA; LAPALME, 2009).

$$\text{Precisão} = \frac{TP}{TP + FP}. \quad (2.2)$$

O *Recall*, ou sensibilidade, mensura a capacidade do modelo em identificar corretamente todas as instâncias positivas. Altos valores de *Recall* indicam menor ocorrência de falsos negativos, mas podem vir acompanhados de queda na precisão, especialmente em contextos de classes desbalanceadas (FAWCETT, 2006).

$$\text{Recall} = \frac{TP}{TP + FN}. \quad (2.3)$$

O *F1-Score* corresponde à média harmônica da Precisão e do *Recall*. Essa medida é útil para avaliar o desempenho do modelo em cenários onde é necessário equilibrar a ocorrência de falsos positivos e falsos negativos, embora também possa ser sensível ao desbalanceamento entre as classes (RIJSBERGEN, 1979).

$$F1\text{-Score} = 2 \times \frac{\text{Precisão} \times \text{Recall}}{\text{Precisão} + \text{Recall}}. \quad (2.4)$$

O Coeficiente *Kappa* de Cohen avalia o grau de concordância entre as predições do modelo e as classificações reais, considerando o nível de concordância esperada ao acaso. O *Kappa* é indicado para conjuntos desbalanceados, por considerar a concordância ao acaso e oferecer uma avaliação mais robusta que a Acurácia (COHEN, 1960).

$$Kappa(\kappa) = \frac{P(A) - P(E)}{1 - P(E)}. \quad (2.5)$$

3 Trabalhos Relacionados

Nesta seção, serão apresentados e discutidos os principais trabalhos voltados para a detecção automática da LV. Os trabalhos relacionados foram selecionados de acordo com três principais critérios: (1) Qual exame foi utilizado para a captura de imagens? (2) O estudo utiliza imagens provenientes de humanos ou animais? (3) Quais técnicas de VC o estudo utiliza? A análise destes trabalhos incluirá uma descrição dos principais objetivos, as metodologias empregadas, os resultados alcançados e as limitações identificadas em cada estudo, proporcionando uma visão abrangente do estado atual da pesquisa nessa área, destacando as principais contribuições, os desafios enfrentados e as oportunidades para melhorias na metodologia, conforme apresentado na Tabela 1. Destaca-se que, ao contrário dos estudos aqui analisados, a proposta deste trabalho concentra-se especificamente na classificação de macrófagos, células-chave no diagnóstico parasitológico da LV.

Tabela 1 – Tabela de Trabalhos Relacionados

Trabalho	Exame	Paciente	Técnicas de VC
(GONÇALVES et al., 2022)	Parasitológico	Humano	LeNet, InceptionResNetV2, InceptionV3, NASNetLarge, ResNet152V2, Xception
(NAKAMURA et al., 2022)	Parasitológico	Humano	UNet, DeepLabV3+, SegFormer
(RIOS et al., 2022)	Parasitológico	Humano	UNet, DeepLabV3+, SegFormer-B3
(MARINHO et al., 2020)	Parasitológico	Humano	SCNN
(GONÇALVES et al., 2023a)	Parasitológico	Humano	U-Net
(GÓRRIZ et al., 2018)	Parasitológico	Humano	U-Net
Este trabalho	Parasitológico	Canino	DenseNet201, MobileNet, MobileNetV2, ResNet50, ResNet50V2

O estudo proposto por [Gonçalves et al. \(2022\)](#) automatiza a classificação da LV utilizando uma base de dados composta por 151 imagens, das quais 79 são positivas e 72 são negativas. Duas abordagens foram utilizadas para o experimento. A primeira envolve uma CNN baseada na arquitetura LeNet, que alcançou uma Acurácia máxima de 78,7% e um *Recall* máximo de 64%. A segunda abordagem emprega um extrator de características que utiliza as seguintes CNNs pré-treinadas: InceptionResNetV2 ([SZEGEDY et al., 2017](#)), InceptionV3 ([SZEGEDY et al., 2016](#)), NASNetLarge ([ZOPH et al., 2018](#)), ResNet152V2 ([HE et al., 2016a](#)) e Xception ([CHOLLET, 2017](#)). A NASNetLarge demonstrou o melhor

desempenho, com um *Recall* de 75%, a Precisão de 94% e uma Acurácia de 64%. Apesar dos resultados notáveis, o estudo utilizou uma base de dados que se trata de LV em humanos e não se concentrou na identificação de estruturas celulares como os macrófagos.

O estudo proposto por Nakamura et al. (2022) utiliza técnicas de VC para calcular o índice de infecção por LV a partir da captura e processamento de imagens microscópicas. As redes neurais utilizadas foram UNet (RONNEBERGER; FISCHER; BROX, 2015), DeepLabV3+ (CHEN et al., 2018) e SegFormer (XIE et al., 2021), baseadas em segmentação semântica com pós-processamento para quantificação das instâncias. Essas redes foram empregadas para calcular índices como a contagem total de macrófagos, quantidade de macrófagos infectados por *Leishmanias* e quantidade total de parasitas. Os resultados mostraram rapidez e precisão nos cálculos, demonstrando a viabilidade para uso prático. No entanto, o foco do estudo estava na quantificação e não na classificação específica dos macrófagos enquanto objetos isolados de interesse.

O estudo proposto por Rios et al. (2022) automatiza a quantificação do índice de infecção por LV em macrófagos, utilizando um conjunto de dados composto por 606 imagens adquiridas por *smartphones* acoplados a microscópios. Três abordagens de CNNs foram utilizadas para segmentação semântica das imagens: UNet (RONNEBERGER; FISCHER; BROX, 2015), DeepLabV3+ (CHEN et al., 2018) e SegFormer-B3 (XIE et al., 2021). A SegFormer-B3 demonstrou o melhor desempenho, com média de Intersection over Union (IoU) por classe de 0,4602 e IoU geral de 0,6855. As métricas de avaliação incluíram MAE, RMSE e coeficiente de determinação (R²), que alcançou 0,8653 no conjunto de teste filtrado. O método proposto demonstrou eficiência na contagem de *Leishmanias*, mas, assim como o estudo anterior, não abordou a classificação individual de macrófagos.

O estudo proposto por Marinho et al. (2020) automatiza o diagnóstico da LV utilizando uma base de dados composta por 76 imagens de esfregaços de medula óssea de pacientes com LV. A metodologia emprega uma arquitetura de CNN Siamês Profunda (SCNN) (CHOPRA; HADSELL; LECUN, 2005), treinada com pares de imagens para aprender representações em bases de dados desbalanceadas. A SCNN desenvolvida alcançou Acurácia de 83%, superando métodos tradicionais e fornecendo precisão superior à dos especialistas humanos. As imagens utilizadas foram provenientes de pacientes humanos, e não há menção específica à segmentação ou análise de macrófagos.

O estudo de Gonçalves et al. (2023a) automatizou a detecção de parasitas da LV em imagens de microscopia de medula óssea utilizando a U-Net. O conjunto de dados continha 150 imagens, com 78 positivas. As métricas obtidas foram Dice de 80,4%, IoU de 75,2%, Acurácia de 99,1%, Precisão de 81,5%, *Recall* de 72,2%, especificidade de 99,6% e AUC de 86,5%. Os resultados indicam que modelos de *deep learning* treinados com imagens de lâminas parasitológicas podem auxiliar especialistas na detecção de LV. No entanto, o foco permanece na detecção geral do parasita, sem detalhamento sobre a identificação celular dos macrófagos envolvidos no processo infeccioso.

O estudo de [Górriz et al. \(2018\)](#) automatiza a segmentação e classificação de parasitas de leishmaniose em imagens microscópicas utilizando *deep learning*. Foi utilizada a U-Net treinada para segmentar parasitas em culturas de células infectadas por diferentes espécies de *Leishmania*. O conjunto de dados incluiu 45 imagens de macrófagos infectados, anotadas manualmente para identificação de promastigotas, amastigotas e parasitas aderidos. As métricas foram: Precisão de 51,2% (promastigotas), 67,7% (parasitas aderidos) e 75,7% (amastigotas); *Recall* de 47,6%, 37,9% e 82,3%; e *F1-Score* de 49,1%, 45,7% e 77,7%, respectivamente. Apesar do foco nas formas parasitárias, o estudo envolveu imagens com macrófagos, mas não teve como objetivo a classificação direta dessas células.

Ao analisar o levantamento do estado da arte, observa-se uma evidente lacuna quanto ao uso de imagens provenientes de cães, bem como à inexistência de sistemas automatizados voltados à classificação de macrófagos, elemento essencial no diagnóstico parasitológico da LV. Considerando as diferenças celulares e morfológicas entre humanos e cães, é notável a necessidade de desenvolver métodos específicos que classifiquem essas células em contextos veterinários, de modo a garantir diagnósticos mais rápidos e precisos. Este trabalho tem como objetivo preencher essa lacuna, propondo uma ferramenta baseada em visão computacional voltada especificamente à detecção e classificação automática de macrófagos em imagens caninas, contribuindo para o diagnóstico da LV em cães.

4 Metodologia

Esta seção apresenta a metodologia abordada neste trabalho para realizar a classificação de macrófagos utilizando técnicas de VC em conjunto a técnicas de *Deep Learning*. A metodologia inclui as seguintes etapas: (1) aquisição de dados, (2) pré-processamento, (3) aumento de dados e (4) classificação, conforme demonstrado na Figura 5.

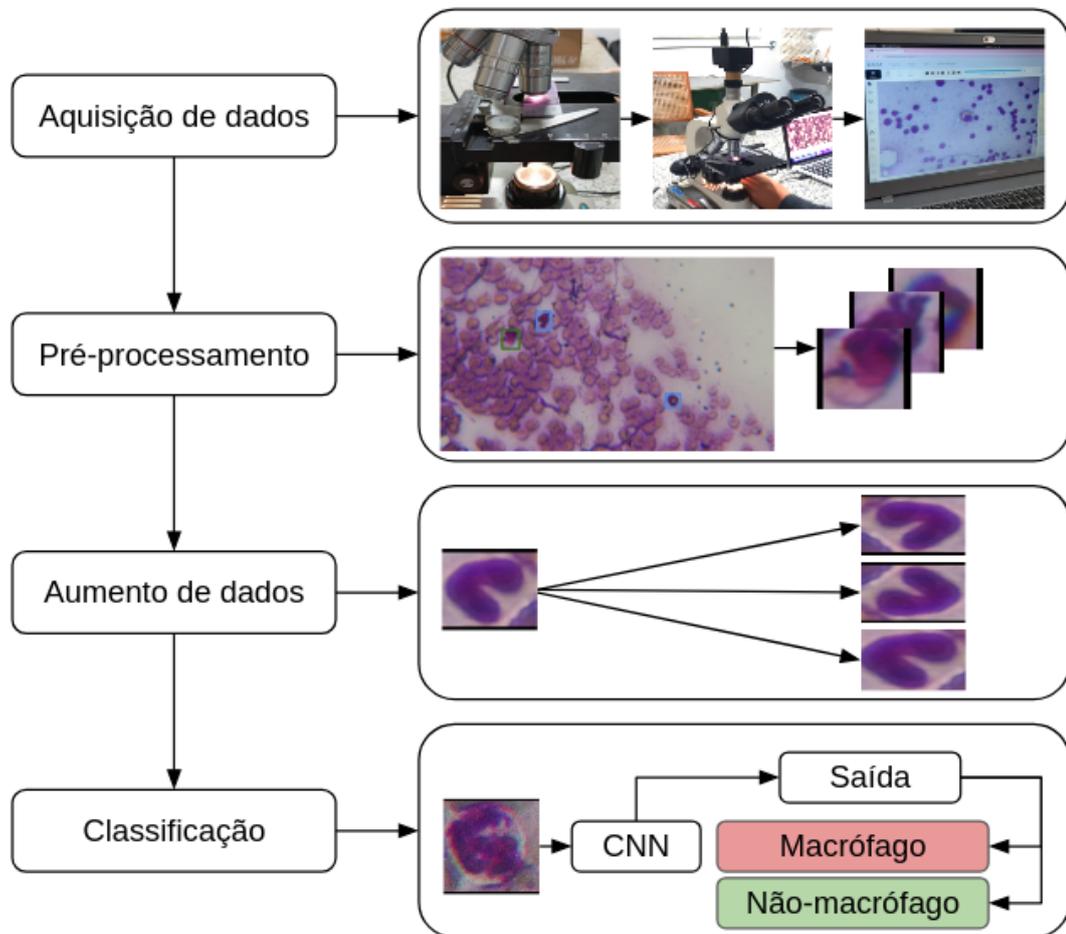


Figura 5 – Fluxograma da metodologia proposta para o desenvolvimento deste trabalho. Fonte: Autoria própria.

4.1 Aquisição de Dados

A coleta da base de imagens para este estudo foi conduzida em colaboração com o Laboratório de Parasitologia, Ecologia e Doenças Negligenciadas (LAPEDONE), utilizando um microscópio focalizado em 40× equipado com uma câmera digital. A procura pelos macrófagos, células que atuam como ambientes propícios para a presença do parasita causador da LV, foi realizada em lâminas contendo amostras biológicas retiradas da medula

óssea do fêmur dos animais. Utilizaram-se duas lâminas capturadas do fêmur de dois cães, e o conjunto de dados obtido foi composto por 178 imagens de resolução 1920×1080 . Neste conjunto, especialistas analisaram e marcaram os macrófagos, e as estruturas classificadas como não-macrófagos. A Figura 6 apresenta as etapas e o processo de captura de dados.

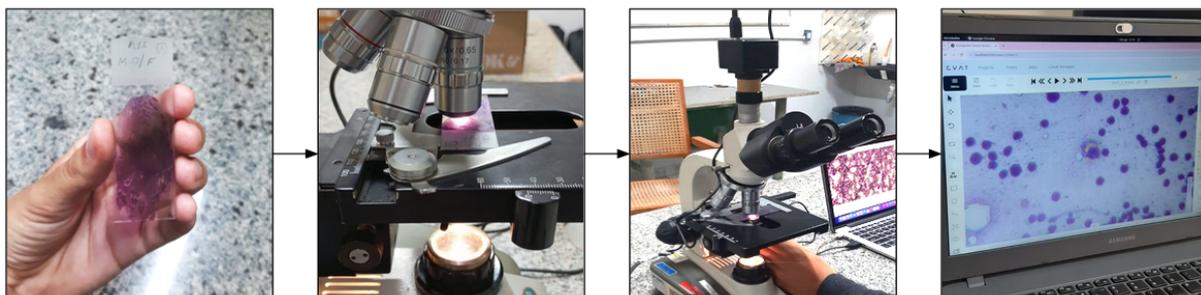


Figura 6 – Etapas da aquisição e anotação de dados. Fonte: Autoria própria.

4.2 Pré-processamento

Durante a etapa de pré-processamento, foram utilizadas as marcações realizadas pelos especialistas no *software* CVAT (CORPORATION, 2019–), para identificar os eixos de cada estrutura e recortar as regiões de interesse das imagens originais. O processo foi feito utilizando a linguagem de programação Python (Python Software Foundation, 2023). Como as marcações das células não têm um tamanho padrão, foram adicionadas bordas contendo o valor 0 para preencher as imagens que não eram quadradas, sempre deixando a estrutura no centro da imagem. Em seguida todos os recortes foram redimensionados para 224×224 , visando compatibilidade com modelos pré-treinados e menor custo computacional, resultando assim em 137 imagens de macrófagos e 278 imagens de não macrófagos, totalizando 415 recortes. A base de dados obtida através dos recortes foi dividida em 60% para treino, 20% para teste e 20% para validação. A Figura 7 mostra exemplos de recortes de macrófagos, e a Figura 8 apresenta exemplos de não-macrófagos.

4.3 Aumento de Dados

Durante a metodologia, foram utilizadas técnicas de ampliação de dados, implementados com a biblioteca *Albumentantitons* (FARHADI; ARDESHIR, 2018) para potencializar o treinamento das CNNs. As técnicas aplicadas foram a rotação aleatória nos eixos vertical e horizontal, e a aplicação de zoom aleatório nos valores entre 0 e 0,1, já que as estruturas não contém padrões definidos de formato ou tamanho, Essas variações foram selecionadas para preservar as estruturas das células, minimizando a perda de informações importantes.. Essa técnica de aumento de dados foi utilizada apenas na classe de macrófagos a fim de diversificar a variedade dos dados de treinamento e balancear as bases, considerando

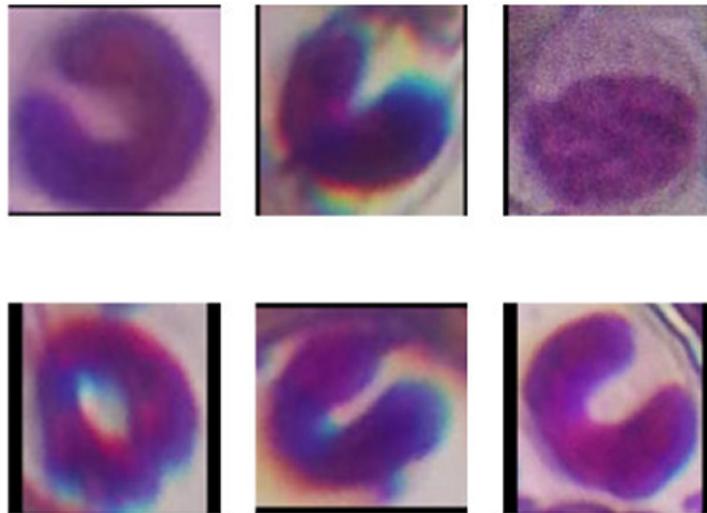


Figura 7 – Estruturas classificadas como macrófagos. Fonte: Autoria própria.

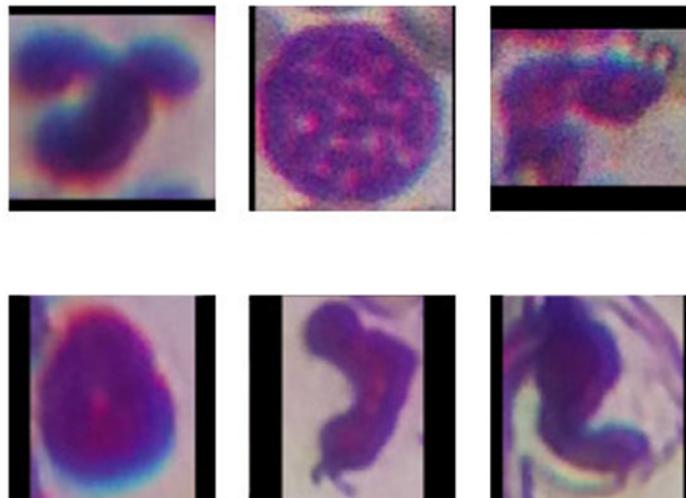


Figura 8 – Estruturas classificadas como não-macrófagos. Fonte: Autoria própria.

as diferenças no número de imagens. Após a aplicação do aumento, ambas as classes na base de treino ficaram com 194 imagens. A Figura 9 apresenta exemplos da aplicação de aumento de dados, demonstrando como as variações foram aplicadas às imagens para diversificar o conjunto de treinamento e melhorar a robustez do modelo.

Além do aumento de dados, foi realizado um ajuste por meio da remoção aleatória de imagens da classe de não macrófagos, garantindo que ambas as classes tivessem a mesma quantidade de dados no conjunto de teste. Essa adaptação foi efetuada na classe de não macrófagos de forma aleatória, assegurando que ambas as classes possuísem a mesma quantidade de dados no conjunto de teste. Essa técnica foi aplicada para garantir uma distribuição balanceada entre as classes, contribuindo para uma avaliação justa e imparcial do desempenho do modelo em ambas as categorias.

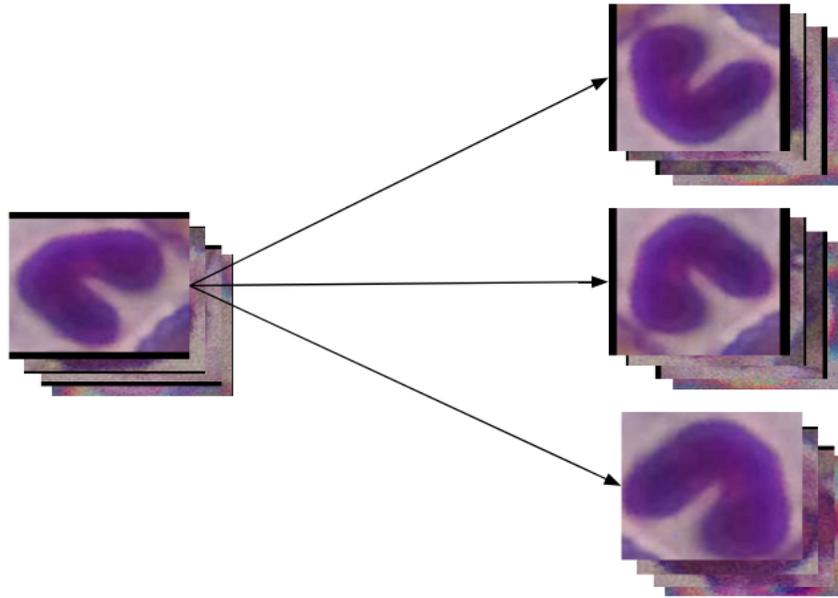


Figura 9 – Exemplo de aumento nos dados. Fonte: Autoria própria.

4.4 Classificação de Imagens

Neste trabalho, foram utilizados cinco modelos de CNNs como ferramentas para extrair atributos e realizar de forma precisa a classificação de imagens em relação a presença de macrófagos. CNNs são tipos de Redes Neurais Artificiais que usam multicamadas complexas e profundas, capazes de reconhecer elementos em imagens (GOODFELLOW; BENGIO; COURVILLE, 2016). Para este trabalho as CNNs escolhidas foram: DenseNet201 (HUANG et al., 2017), MobileNet (HOWARD et al., 2017); MobileNetV2 (SANDLER et al., 2019); ResNet50 (HE et al., 2015); e ResNet50V2 (HE et al., 2016b), estes modelos foram escolhidos devido à sua menor quantidade de parâmetros e à eficiência no tempo de inferência por etapa na GPU, garantindo uma execução mais rápida e um consumo de recursos reduzido durante o treinamento e a inferência, como mostra a Tabela 2. Outro método também utilizado, foi a transferência de aprendizado, essa técnica foi usada em decorrência do número pequeno de imagens na base de dados e da significativa otimização no processo de treino das redes.

Tabela 2 – Informações de parâmetros sobre as CNNs utilizadas durante este trabalho.

Modelo	Tamanho (MB)	Parâmetros	Tempo inferência (GPU)
DenseNet201	80	20,2M	6,7ms
ResNet50	98	25,6M	4,6ms
ResNet50V2	98	25,6M	4,4ms
MobileNet	16	4,3M	3,4ms
MobileNetV2	14	3,5M	3,8ms

Durante o treinamento, foi usada a estratégia de congelamento das camadas convolu-

cionais, preservando os extratores de características já estabelecidos na etapa de transferência de aprendizagem. Essa abordagem foi adotada com o intuito de evitar alterações que pudessem comprometer a qualidade dos resultados. Após à classificação, foi implementada a técnica de *fine-tuning*. Essa prática envolveu o descongelamento das camadas convolucionais, permitindo que o modelo fosse treinado integralmente com o conjunto de dados mencionado anteriormente. Os parâmetros escolhidos para o treinamento da rede exercem influência direta em sua performance. Neste estudo, conduzimos 30 épocas de treinamento e 60 épocas de *fine-tuning*, permitindo que o modelo aprenda representações iniciais robustas e ajuste com precisão seus parâmetros. A taxa de aprendizado de 0,01 foi adotada por ser um valor intermediário, visando um equilíbrio entre convergência eficiente e estabilidade durante o processo de treinamento.

4.5 Avaliação de Desempenho

Nesta etapa, o desempenho dos modelos foi avaliado por meio das métricas apresentadas no referencial teórico: Acurácia, Precisão, *Recall*, *F1-Score* e Coeficiente *Kappa*. Essas métricas foram calculadas a partir das previsões realizadas sobre o conjunto de teste, que foi previamente balanceado para garantir uma distribuição equitativa entre as classes. Durante as fases de treinamento e *fine-tuning*, a evolução dessas métricas foi monitorada para acompanhar o processo de aprendizado das redes neurais. Ao final do treinamento, as métricas foram utilizadas para uma análise detalhada da capacidade dos modelos em distinguir macrófagos de não-macrófagos. Essa abordagem permitiu avaliar os classificadores, compreender o equilíbrio na identificação correta das diferentes classes, e detectar possíveis falhas que poderiam comprometer a aplicação prática do sistema.

5 Resultados

Na metodologia deste trabalho, o valor de entrada utilizada pelas imagens em cada CNN foi padronizada de 224×224 em formato RGB. A análise inclui duas fases, antes e após a implementação do *fine-tuning*. A Tabela 3 apresenta os resultados obtidos durante as duas fases do experimento. A primeira parte mostra os resultados obtidos com o uso de CNNs, enquanto a segunda parte exhibe os resultados após a aplicação do *fine-tuning*. A Figura 10 mostra as imagens que a rede classificou incorretamente, e a Figura 11 mostra alguns dos exemplos de imagens que a rede classificou corretamente. A Tabela 4 apresenta a comparação entre os resultados obtidos neste trabalho com os resultados da literatura.

Tabela 3 – Resultados obtidos através da CNN e com a aplicação do *fine-tuning*.

CNN	Acurácia	Precisão	Recall	F1-Score	Kappa
<i>Sem Fine-Tuning</i>					
DenseNet201	0,80	0,84	0,76	0,79	0,61
ResNet50	0,88	0,99	0,80	0,88	0,76
ResNet50V2	0,76	0,76	0,76	0,76	0,52
MobileNet	0,85	0,89	0,80	0,84	0,71
MobileNetV2	0,88	0,86	0,90	0,88	0,76
<i>Com Fine-Tuning</i>					
DenseNet201	0,85	0,82	0,90	0,86	0,71
ResNet50	0,80	0,75	0,90	0,82	0,61
ResNet50V2	0,76	0,76	0,76	0,76	0,52
MobileNet	0,83	0,81	0,85	0,83	0,66
MobileNetV2	0,83	0,85	0,80	0,82	0,66

Tabela 4 – Comparação das métricas dos trabalhos relacionados com este estudo.

Estudo	Acurácia	Precisão	Recall	F1-Score	Kappa
Gonçalves et al. (2022)	0,787	0,94	0,64	0,76	-
Nakamura et al. (2022)	-	-	-	-	-
Rios et al. (2022)	-	-	-	-	-
Marinho et al. (2020)	0,83	-	-	-	-
Gonçalves et al. (2023a)	0,99	0,81	0,72	-	-
Górriz et al. (2018)	-	0,75	0,47	0,49	-
Este trabalho	0,88	0,99	0,80	0,88	0,76

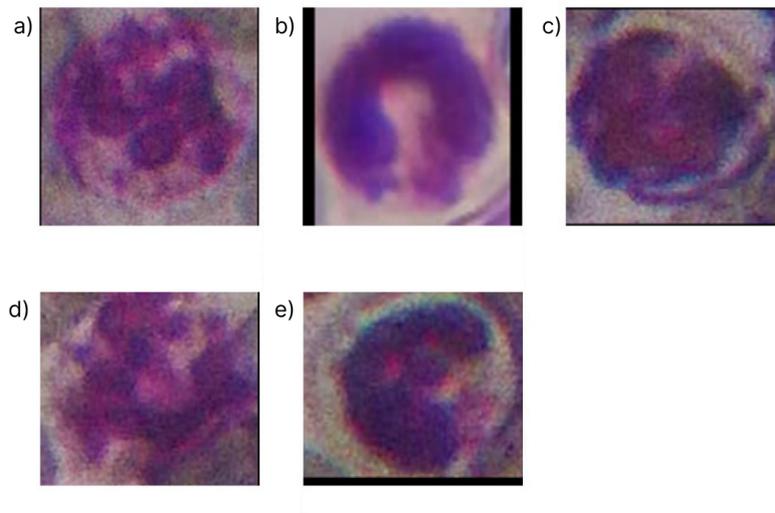


Figura 10 – As imagens a), b), c), d), e) são imagens que foram classificadas erroneamente pela rede como não pertencentes à classe de macrófagos, embora correspondam a macrófagos. Fonte: Autoria própria.

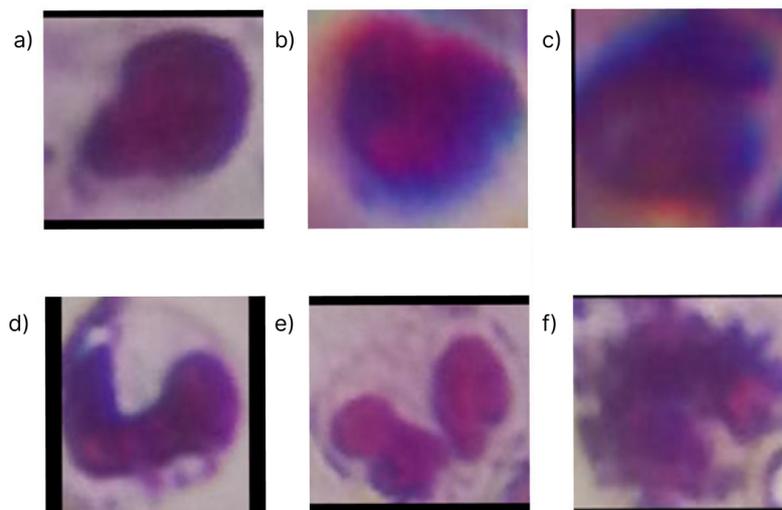


Figura 11 – As imagens a), b), c), d), e) e f) são imagens de não-macrófagos corretamente classificadas pela rede. Fonte: Autoria própria.

5.1 Discussão dos Resultados e Limitações

Ao analisar os resultados obtidos na Tabela 3, é notável que na primeira fase do experimento a ResNet50 se destacou em quase todas as métricas em comparação com as demais CNNs, alcançando os resultados mais relevantes nas métricas de Acurácia, Precisão, *F1-Score* e *Kappa*. Vale ressaltar que a única exceção foi a métrica de *Recall* obtida com o uso da MobileNetV2. Essa diferença destaca a consistência do desempenho da ResNet50, evidenciando sua eficácia em relação às demais arquiteturas de CNN examinadas.

Observando os resultados alcançados após a aplicação do *fine-tuning*, é possível notar variações nos resultados, conforme apresentado na Tabela 3. A DenseNet201 evidencia um desempenho relevante em consideração com os resultados das demais CNNs em Acurácia, *Recall*, *F1-Score* e *Kappa*, embora tenha demonstrado melhorias notáveis em Acurácia e *Recall* após o *fine-tuning*, as métricas obtidas nessa fase permaneceram abaixo da maior parte das métricas alcançadas pela ResNet50 na fase anterior do experimento. Isso pode ser atribuído ao fato de que a taxa de aprendizado utilizada foi 0,01, um valor relativamente alto para o *fine-tuning*, o que pode ter dificultado a convergência do modelo. Além disso, o número elevado de épocas de treinamento durante o *fine-tuning* pode ter causado um ajuste excessivo dos parâmetros, levando a uma performance não otimizada.

A análise dos resultados apresentados na Tabela 3 revela que, entre as CNNs utilizadas, a ResNet50 se destacou como a mais confiável, seguida pela MobileNetV2. A ResNet50 obteve Acurácia, Precisão, *Recall* e *F1-Score* superiores a 85%, além de um valor de *Kappa* superior a 75%, com resultados que superaram os obtidos após a aplicação do *fine-tuning*. Essas métricas indicam que métodos com baixo custo computacional podem gerar avanços significativos, mesmo com recursos limitados de *hardware*, como evidenciado pelas métricas de desempenho obtidas com a ResNet50 e MobileNet. Isso é particularmente relevante quando se considera que, em muitos trabalhos do estado da arte, modelos de CNN muito profundos são empregados para alcançar excelentes resultados, mas com o custo de um alto poder de processamento. Exemplos disso são os estudos de (GONÇALVES et al., 2022) e (NAKAMURA et al., 2022), que utilizam arquiteturas pesadas como InceptionResNetV2, ResNet152V2 e Xception, que, embora altamente eficazes, demandam uma infraestrutura computacional robusta. Por outro lado, os resultados deste estudo sugerem que é possível obter desempenhos relevantes com modelos menos profundos, como a ResNet50 e a MobileNet, evidenciando que é possível equilibrar desempenho e custo computacional mesmo em cenários com recursos limitados, conforme destacado na Tabela 4.

Os resultados obtidos, especialmente com a arquitetura ResNet50, evidenciam o potencial de se alcançar alto desempenho utilizando modelos com baixo custo computacional. No entanto, como em todo estudo experimental, algumas limitações devem ser consideradas na interpretação dos resultados. A principal delas refere-se à variação observada após a aplicação do *fine-tuning*, que em certos casos não superou os valores iniciais, indicando sensibilidade à configuração dos modelos. Além disso, também se destaca a limitação quanto ao número e à diversidade das arquiteturas testadas, o que reduz as possibilidades de comparação mais abrangente entre diferentes abordagens. Por fim, a comparação com trabalhos da literatura foi dificultada pela ausência de padronização entre protocolos de captura, métricas de avaliação e bases de dados. Enquanto a base de dados utilizada neste estudo é composta por imagens de cães, muitos dos trabalhos da literatura se baseiam em dados de humanos, o que limita análises comparativas diretas devido às diferenças nas características das imagens e nos contextos de aplicação.

6 Conclusão

Este trabalho apresentou uma ferramenta baseada em técnicas de VC e aprendizado profundo para a detecção e classificação automática de macrófagos em imagens parasitológicas, com ênfase no diagnóstico da LV em cães. Para tanto, foi construída uma base de dados própria, composta por imagens microscópicas da medula óssea canina, cuidadosamente anotadas por especialistas. Sobre essa base, foram aplicados procedimentos de pré-processamento, técnicas de aumento de dados e foram avaliadas cinco arquiteturas de CNNs para a tarefa de classificação dos macrófagos.

Os resultados indicaram que o modelo ResNet50 apresentou um desempenho consistente, alcançando elevados índices de Acurácia, Precisão, *Recall*, *F1-Score* e *Kappa*, aliados a uma eficiência computacional adequada, aspecto fundamental para aplicações em contextos com recursos limitados. Ressalta-se que a utilização da técnica de transferência de aprendizado, seguida pela etapa de *fine-tuning* não resultou em melhorias significativas na avaliação, indicando a robustez inicial dos modelos para o conjunto de dados empregado.

A comparação com estudos da literatura evidenciou que a proposta é competitiva, destacando-se pela originalidade de aplicar diretamente imagens provenientes de cães, um importante diferencial frente à literatura atual, que é majoritariamente direcionada a imagens humanas. Essa contribuição torna o sistema desenvolvido uma ferramenta promissora para auxiliar o diagnóstico laboratorial da LV canina, com potencial impacto positivo na vigilância epidemiológica e no controle da doença, considerando o papel do cão como principal reservatório no ciclo de transmissão da enfermidade.

Por fim, reconhecem-se as limitações deste estudo, especialmente no que diz respeito ao tamanho e à diversidade da base de dados utilizada. Recomenda-se que pesquisas futuras ampliem o conjunto de imagens, incorporem outras classes parasitológicas relevantes, como a detecção direta de formas amastigotas de *Leishmania*, e investiguem arquiteturas mais modernas, além de métodos de segmentação, com o intuito de aprimorar a precisão do sistema. Ademais, a implementação do modelo em plataformas acessíveis a laboratórios veterinários pode viabilizar a disseminação e o uso prático da tecnologia proposta neste trabalho, contribuindo para o avanço do diagnóstico da LV em âmbito clínico.

Referências

- ÁLVARO, C. I. L. S. *Relatório de Estágio e Monografia intitulada "Leishmaniose Canina: Sintomas e Tratamentos"*. Dissertação (Mestrado), 2022. Citado na página 13.
- BANETH, G. Leishmaniose. In: *Greene: Doenças infecciosas do cão e do gato*. 3^a. ed. Saint Louis: Saunders Elsevier, 2006. p. 685–698. Citado na página 13.
- BARBIERI, C. L. Immunology of canine leishmaniasis. *Parasite Immunol.*, v. 28, n. 7, p. 329–337, 2006. Citado na página 13.
- BRANDÃO, A. S. et al. Redes neurais artificiais aplicadas ao reconhecimento de comandos de voz. *Trabalho de Conclusão de Curso. Engenharia Elétrica, Universidade Federal de Viçosa–UFV–2005*, 2005. Citado na página 21.
- CAMPINO, L.; MAIA, C. Epidemiologia das leishmanioses em portugal. *Acta medica portuguesa*, v. 23, n. 5, p. 859–64, 2010. Citado na página 13.
- CHEN, C. H. *Handbook of Pattern Recognition and Computer Vision*. 5th. ed. World Scientific, 2016. Disponível em: <<https://www.worldscientific.com/doi/abs/10.1142/9503>>. Citado na página 19.
- CHEN, L.-C. et al. Encoder-decoder with atrous separable convolution for semantic image segmentation. *arXiv preprint arXiv:1802.02611*, 2018. Citado na página 23.
- CHOLLET, F. Xception: Deep learning with depthwise separable convolutions. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2017. p. 1251–1258. Citado na página 22.
- CHOPRA, S.; HADSELL, R.; LECUN, Y. Learning a similarity metric discriminatively, with application to face verification. *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, p. 539–546, 2005. Citado na página 23.
- COHEN, J. A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, SAGE Publications, v. 20, n. 1, p. 37–46, 1960. Citado na página 21.
- CORPORATION, I. *CVAT: Computer Vision Annotation Tool*. 2019–. <https://github.com/openvinotoolkit/cvat>. Software disponível em: <https://github.com/openvinotoolkit/cvat>. Disponível em: <<https://github.com/openvinotoolkit/cvat>>. Citado na página 26.
- FARHADI, A.; ARDESHIR, S. *Albumentations*. 2018. <https://github.com/albumentations-team/albumentations>. A fast and flexible image augmentations library. Citado na página 26.
- FARIA, A. R.; ANDRADE, H. M. de. Diagnóstico da leishmaniose visceral canina: grandes avanços tecnológicos e baixa aplicação prática. *Revista Pan-Amazônica de Saúde*, v. 3, n. 2, p. 11–11, 2012. Citado na página 18.
- FAWCETT, T. An introduction to roc analysis. *Pattern Recognition Letters*, Elsevier, v. 27, n. 8, p. 861–874, 2006. Citado na página 21.

- GONÇALVES, C. et al. Detection of human visceral leishmaniasis parasites in microscopy images from bone marrow parasitological examination. *Applied Sciences*, MDPI, v. 13, n. 14, p. 8076, 2023. Citado 3 vezes nas páginas 22, 23 e 30.
- GONÇALVES, C. et al. Computer vision in automatic visceral leishmaniasis diagnosis: a survey. *IEEE Latin America Transactions*, IEEE, v. 21, n. 2, p. 310–319, 2023. Citado na página 14.
- GONÇALVES, C. d. A. et al. Método automático para detecção de leishmaniose visceral em humanos. 2022. Citado 4 vezes nas páginas 13, 22, 30 e 32.
- GONTIJO, C. M.; MELO, M. N. Leishmaniose visceral no brasil: quadro atual, desafios e perspectivas. *Revista Brasileira de Epidemiologia*, v. 7, n. 3, p. 338–349, 2004. Citado na página 18.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep learning*. [S.l.]: MIT press, 2016. Citado na página 28.
- GÓRRIZ, M. et al. Leishmaniasis parasite segmentation and classification using deep learning. In: SPRINGER. *Articulated Motion and Deformable Objects: 10th International Conference, AMDO 2018, Palma de Mallorca, Spain, July 12-13, 2018, Proceedings 10*. [S.l.], 2018. p. 53–62. Citado 3 vezes nas páginas 22, 24 e 30.
- HE, H.; GARCIA, E. A. Learning from imbalanced data. *IEEE Transactions on Knowledge and Data Engineering*, IEEE, v. 21, n. 9, p. 1263–1284, 2009. Citado na página 21.
- HE, K. et al. *Deep Residual Learning for Image Recognition*. 2015. Citado na página 28.
- HE, K. et al. Identity mappings in deep residual networks. In: SPRINGER. *European Conference on Computer Vision*. [S.l.], 2016. p. 630–645. Citado na página 22.
- HE, K. et al. *Identity Mappings in Deep Residual Networks*. 2016. Citado na página 28.
- HOWARD, A. G. et al. *MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications*. 2017. Citado na página 28.
- HUANG, G. et al. Densely connected convolutional networks. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. [S.l.: s.n.], 2017. Citado na página 28.
- IVĂNESCU, L. et al. The immune response in canine and human leishmaniasis and how this influences the diagnosis—a review and assessment of recent research. *Frontiers in Cellular and Infection Microbiology*, Frontiers Media SA, v. 13, 2023. Citado na página 13.
- KUMAR, R.; NYLÉN, S. Immunobiology of visceral leishmaniasis. *Frontiers in Immunology*, Frontiers Research Foundation, v. 3, p. 251, 2012. Citado na página 13.
- LARAIA, A. C.; SANTANA, K.; DONATO, L. E. Avaliação da resposta de anticorpos vacinais em animais vacinados contra leishmaniose visceral canina. *Programa de Iniciação Científica-PIC/UniCEUB-Relatórios de Pesquisa*, v. 4, n. 1, 2018. Citado 2 vezes nas páginas 8 e 18.

- LEBEDEV, G. et al. Application of artificial intelligence methods to recognize pathologies on medical images. *Elsevier B.V.*, v. 126, p. 1171–1177, 2018. Citado na página 17.
- MARINHO, T. T. et al. Aspectos clínicos laborais e o uso da modelagem computacional no diagnóstico da leishmaniose visceral. Universidade Federal de Alagoas, 2020. Citado 3 vezes nas páginas 22, 23 e 30.
- MASSUCATTO, J. D. P. *Aplicação de conceitos de redes neurais convolucionais na classificação de imagens de folhas*. Dissertação (B.S. thesis) — Universidade Tecnológica Federal do Paraná, 2018. Citado na página 20.
- NAKAMURA, V. R. et al. Desenvolvimento de aplicativo móvel para o cálculo do índice de infecção por leishmaniose usando visão computacional. Pontifícia Universidade Católica de Goiás, 2022. Citado 4 vezes nas páginas 22, 23, 30 e 32.
- NIXON, M.; AGUADO, A. *Feature Extraction and Image Processing for Computer Vision*. 4th. ed. [S.l.]: Academic Press, 2019. Citado na página 20.
- Organização Pan-Americana da Saúde. *Leishmaniose*. 2024. Acesso em: 13 jun. 2025. Disponível em: <<https://www.paho.org/pt/topicos/leishmaniose>>. Citado na página 13.
- Pan American Health Organization. *Visceral Leishmaniasis*. 2022. <https://www.paho.org/en/topics/leishmaniasis/visceral-leishmaniasis>. Acessado em 11 de janeiro de 2024. Citado na página 13.
- PARKER, J. *Algorithms for Image Processing and Computer Vision*. 2nd. ed. [S.l.]: Wiley Publishing, 2010. Citado na página 19.
- PINELLI, E. et al. Cellular and humoral immune responses in dogs experimentally and naturally infected with *Leishmania infantum*. *Infect. Immun.*, v. 62, n. 1, p. 229–235, 1994. Citado na página 13.
- POWERS, D. M. W. Evaluation: From precision, recall and f-measure to roc, informedness, markedness and correlation. *Journal of Machine Learning Technologies*, v. 2, n. 1, p. 37–63, 2011. Citado na página 21.
- Python Software Foundation. *Python Language Reference, version 3.11*. Beaverton, Oregon, USA, 2023. Disponível em: <<https://www.python.org/>>. Citado na página 26.
- REITHINGER, R.; DUJARDIN, J. Molecular diagnosis of leishmaniasis: current status and future applications. *Journal of Clinical Microbiology*, American Society for Microbiology, v. 45, p. 21–25, 2007. Citado na página 17.
- RIJSBERGEN, C. V. *Information Retrieval*. 2nd. ed. [S.l.]: Butterworth-Heinemann, 1979. Citado na página 21.
- RIOS, W. S. R. et al. Segmentação de imagens microscópicas para quantificação da infecção de leishmaniose em macrófagos com visão computacional. Pontifícia Universidade Católica de Goiás, 2022. Citado 3 vezes nas páginas 22, 23 e 30.

- RODRIGUEZ, A. B. et al. Diagnostic model of visceral leishmaniasis based on bone marrow findings. study of patients with clinical suspicion in which the parasite is not observed. *European Journal of Internal Medicine*, v. 69, p. 42–49, 2019. Citado na página 19.
- RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: Convolutional networks for biomedical image segmentation. In: SPRINGER. *International Conference on Medical image computing and computer-assisted intervention*. [S.l.], 2015. p. 234–241. Citado na página 23.
- SAKKAS, H.; GARTZONIKA, C.; LEVIDIOTOU, S. Laboratory diagnosis of human visceral leishmaniasis. *Journal of Vector Borne Diseases*, v. 53, n. 1, p. 8, 2016. Citado na página 19.
- SALAZAR, J. et al. Semi-automatic detection of the evolutionary forms of visceral leishmaniasis in microscopic blood smears. *Journal of Physics: Conference Series*, v. 1386, p. 012135, 2019. Disponível em: <<https://doi.org/10.1088/1742-6596/1386/1/012135>>. Citado na página 20.
- SANDLER, M. et al. *MobileNetV2: Inverted Residuals and Linear Bottlenecks*. 2019. Citado na página 28.
- SANTOS, T. T. O. et al. Potential of recombinant lihyq, a novel *Leishmania infantum* protein, for the diagnosis of canine visceral leishmaniasis and as a diagnostic and prognostic marker for human leishmaniasis and human immunodeficiency virus co-infection: A preliminary study. *Acta Tropica*, v. 224, p. 106126, 2021. Citado na página 13.
- SAÚDE, O. P.-A. d. Leishmanioses: Informe epidemiológico das américas. núm. 12 (dezembro de 2023). *iris.paho.org*, 2023. Disponível em: <<https://iris.paho.org/handle/10665.2/59170>>. Citado 3 vezes nas páginas 8, 17 e 18.
- SCHERER, R. *Computer Vision Methods for Fast Image Classification and Retrieval*. 1st. ed. [S.l.]: Springer Cham, 2020. Citado na página 20.
- SHORTLIFFE, E. H.; CIMINO, J. J. *Biomedical Informatics: Computer Applications in Health Care and Biomedicine*. 4th. ed. [S.l.]: Springer, 2014. Citado na página 20.
- SILVA, C. G. et al. Ultraestrutura de parasitos do gênero leishmania. *Leishmanioses do Continente Americano; Conceição-Silva, F., Alves, CR, Eds*, p. 53–67, 2014. Citado na página 19.
- SILVA, R. R. et al. Radial feature descriptors for cell classification and recommendation. *Journal of Visual Communication and Image Representation*, Elsevier, v. 62, p. 105–116, 2019. Citado na página 13.
- SILVA, R. R. V. e et al. Optic disc detection in retinal images using algorithms committee with weighted voting. *IEEE Latin America Transactions*, IEEE, v. 14, n. 5, p. 2446–2454, 2016. Citado na página 14.
- SILVA, S. *Avaliação clínica e laboratorial de cães naturalmente infectados por Leishmania (Leishmania) chagasi (cunha & chagas, 1937), submetidos a um protocolo terapêutico em clínica veterinária de Belo Horizonte*. Tese (Dissertação) — Universidade Federal de Minas Gerais, Setor de Parasitologia, Belo Horizonte (MG), 2007. Citado na página 18.

- SOKOLOVA, M.; LAPALME, G. A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, Elsevier, v. 45, n. 4, p. 427–437, 2009. Citado na página 21.
- SOLANO-GALLEGO, L. et al. The ibizian hound presents a predominantly cellular immune response against natural leishmania infection. *Veterinary Parasitology*, v. 90, n. 1–2, p. 37–45, 2000. Citado na página 19.
- SRIVIDYA, G. et al. Diagnosis of visceral leishmaniasis: developments over the last decade. *Parasitology Research*, v. 110, n. 3, p. 1065–1078, 2012. Citado na página 18.
- SUNDAR, S.; RAI, M. Laboratory diagnosis of visceral leishmaniasis. *Clinical and Vaccine Immunology*, v. 9, n. 5, p. 951–958, 2002. Citado na página 17.
- SUNDAR, S.; SINGH, O. Molecular diagnosis of visceral leishmaniasis. *Molecular Diagnosis & Therapy*, v. 22, n. 4, p. 443–457, 2018. Citado na página 19.
- SZEGEDY, C. et al. Inception-v4, inception-resnet and the impact of residual connections on learning. In: *Thirty-First AAAI Conference on Artificial Intelligence*. [S.l.: s.n.], 2017. Citado na página 22.
- SZEGEDY, C. et al. Rethinking the inception architecture for computer vision. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2016. p. 2818–2826. Citado na página 22.
- THAKUR, S.; JOSHI, J.; KAUR, S. Leishmaniasis diagnosis: an update on the use of parasitological, immunological and molecular methods. *J. Parasit Dis.*, v. 44, n. 2, p. 253–272, 2020. Citado na página 13.
- World Health Organization. *Leishmaniasis – Key facts*. 2023. Accessed: 2025-06-13. Disponível em: <<https://www.who.int/news-room/fact-sheets/detail/leishmaniasis>>. Citado na página 13.
- WU, J. Introduction to convolutional neural networks. *National Key Lab for Novel Software Technology. Nanjing University. China*, v. 5, n. 23, p. 495, 2017. Citado na página 20.
- XIE, E. et al. Segformer: Simple and efficient design for semantic segmentation with transformers. *arXiv preprint arXiv:2105.15203*, 2021. Citado na página 23.
- ZHANG, B. Computer vision vs. human vision. In: *9th IEEE International Conference on Cognitive Informatics (ICCI'10)*. [S.l.: s.n.], 2010. p. 3–3. Citado na página 20.
- ZOPH, B. et al. Learning transferable architectures for scalable image recognition. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2018. p. 8697–8710. Citado na página 22.



**TERMO DE AUTORIZAÇÃO PARA PUBLICAÇÃO DIGITAL NA BIBLIOTECA
“JOSÉ ALBANO DE MACEDO”**

Identificação do Tipo de Documento

- Tese
- Dissertação
- Monografia
- Artigo

Eu, Viviane Barbosa Leal Dias, autorizo com base na Lei Federal nº 9.610 de 19 de Fevereiro de 1998 e na Lei nº 10.973 de 02 de dezembro de 2004, a biblioteca da Universidade Federal do Piauí a divulgar, gratuitamente, sem ressarcimento de direitos autorais, o texto integral da publicação Classificação Automática de Macrófagos com Visão Computacional para Apoio ao Diagnóstico da Leishmaniose Visceral Canina de minha autoria, em formato PDF, para fins de leitura e/ou impressão, pela internet a título de divulgação da produção científica gerada pela Universidade.

Picos-PI 01 de julho de 2025.

Assinatura