

Universidade Federal do Piauí
Centro de Ciências da Natureza
Programa de Pós-Graduação em Ciência da Computação

Sistema Integrado para Diagnóstico Automatizado da Leishmaniose Visceral em Imagens Microscópicas

Lucas Bezerra Marques de Souza

Número de Ordem PPGCC: M001

Teresina-PI, 08 de Setembro de 2025

Lucas Bezerra Marques de Souza

Sistema Integrado para Diagnóstico Automatizado da Leishmaniose Visceral em Imagens Microscópicas

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação da UFPI (Visão Computacional: Sistemas de Computação), como parte dos requisitos necessários para a obtenção do Título de Mestre em Ciência da Computação.

Universidade Federal do Piauí - UFPI

Centro de Ciências da Natureza

Programa de Pós-Graduação em Ciência da Computação

Orientador: Romuere Rodrigues Veloso e Silva

Teresina-PI

08 de Setembro de 2025

FICHA CATALOGRÁFICA
Universidade Federal do Piauí
Biblioteca Comunitária Jornalista Carlos Castello Branco
Divisão de Representação da Informação

S725s Souza, Lucas Bezerra Marques de.
Sistema Integrado para diagnóstico automatizado da leishmaniose visceral em imagens microscópicas / Lucas Bezerra Marques de Souza. -- 2025.
62 f.

Dissertação (Mestrado) – Universidade Federal do Piauí, Centro de Ciências da Natureza, Programa de Pós-Graduação em Ciências da Computação, Teresina, 2025.
"Orientador: Romuere Rodrigues Veloso e Silva"

1. Processamento de imagens. 2.Sistemas de diagnóstico automatizado. 3. Leishmaniose visceral - Imagens microscópicas. 4. Análise de imagens microscópicas. I. Silva, Romuere Rodrigues Veloso e. II. Título.

CDD 006.37

Bibliotecária: Milane Batista da Silva – CRB3/1005

Lucas Bezerra Marques de Souza

Sistema Integrado para Diagnóstico Automatizado da Leishmaniose Visceral em Imagens Microscópicas

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação da UFPI (Visão Computacional: Sistemas de Computação), como parte dos requisitos necessários para a obtenção do Título de Mestre em Ciência da Computação.

Romuere Rodrigues Veloso e Silva
Orientador

Ana Carolina Landim Pacheco
Membro da Banca

Flávio Henrique Duarte de Araújo
Membro da Banca

Iális Cavalcante de Paula Júnior
Membro da Banca

Teresina-PI

08 de Setembro de 2025

Aos meus pais Eusdeth da Costa e Paulo Jorge pela criação,
e a minha namorada Vanessa Matias,
por sempre estar comigo em todos os momentos.

Agradecimentos

Gostaria de expressar minha profunda gratidão a todas as pessoas que contribuíram para o sucesso deste trabalho. Em primeiro lugar, agradeço à minha família, em especial aos meus pais, Eusdeth da Costa e Paulo Jorge, minhas irmãs, Poliane e Paula Fernanda, meus primos, Mailson e Marcos Raniere, e minha tia, Ivonete Marques. Um agradecimento mais que especial à minha namorada e companheira, Vanessa Matias, pela paciência e incentivo em toda esta caminhada. O apoio de vocês foi fundamental para eu superar os desafios e conquistar essa realização.

Agradeço imensamente ao meu orientador, Prof. Dr. Romuere Rodrigues Veloso e Silva, por todo o conhecimento transmitido, pela confiança e pelas sugestões valiosas que aprimoraram este trabalho. Estendo minha gratidão a todos os professores, tanto da graduação quanto do mestrado, que contribuíram de forma significativa para minha formação acadêmica.

Ao meu grupo de pesquisa, minha gratidão pela colaboração e apoio. Agradeço especialmente a Kawan, Armando, Viviane, Clésio, Rafael, Clara e à professora Ana Carolina, que contribuíram imensamente para o desenvolvimento desta pesquisa.

Por fim, agradeço aos amigos que fiz durante a graduação e que seguiram comigo: Marcos Paulo, Lucas Sousa, Gabriell Oliveira, Thaliane Gomes, Samuel Oliveira e Samuel Lélis. Agradeço por todo o conhecimento que compartilhamos e pelos momentos de descontração.

Resumo

A Leishmaniose Visceral (LV) é uma doença infecciosa grave causada por protozoários do gênero *Leishmania* e transmitida por insetos flebotomíneos. O diagnóstico tradicional por microscopia, embora seja o padrão-ouro, enfrenta desafios como a subjetividade da análise e a dependência da experiência do observador. Este trabalho propõe o desenvolvimento de um sistema web integrado a uma plataforma automatizada de captura de imagens microscópicas, com o objetivo de aprimorar a identificação de amastigotas de *Leishmania* com modelos de *deep learning*. O sistema implementa uma plataforma colaborativa para gerenciamento de laboratórios, com controle de participantes e sistema de convites. A validação da solução ocorreu em três frentes principais. Primeiro, o dispositivo de captura robótico, com custo aproximado de R$ 305,00, demonstrou viabilidade econômica e eficiência operacional, atingindo uma taxa de 8,57 imagens por minuto, superando o método manual (3,33 imagens por minuto). Segundo, os testes de usabilidade da aplicação web, utilizando a escala SUS, resultaram em pontuação média de 76,2, indicando boa aceitação pelos usuários. Terceiro, a plataforma integrou modelos de *deep learning* para diagnóstico de Leishmaniose Visceral Humana (baseado em InceptionV3) e Canina (baseado em YOLOv8), cujos trabalhos de origem reportam 98,7% de F1-Score e 88,5% de mAP, respectivamente. Os resultados demonstram que a abordagem proposta cumpre seu objetivo, entregando uma ferramenta integrada que contribui para tornar o diagnóstico da Leishmaniose mais acessível e eficiente com a automação da captura, com potencial para implementação em áreas endêmicas e expansão para outras doenças.

Palavras-chaves: Diagnóstico automatizado. Aprendizado profundo. Leishmaniose visceral. Captura de imagens. Microscopia digital.

Abstract

Visceral Leishmaniasis (VL) is a severe infectious disease caused by protozoa of the Leishmania genus and transmitted by phlebotomine sandflies. The traditional diagnosis by microscopy, although the gold standard, faces challenges such as the subjectivity of the analysis and its dependence on the observer's experience. This work proposes the development of a web-based system integrated with an automated platform for capturing microscopic images, aiming to improve the identification of Leishmania amastigotes using deep learning models. The system implements a collaborative platform for laboratory management, with participant control and an invitation system. The solution's validation occurred on three main fronts. First, the robotic capture device, with an approximate cost of R$ 305.00, demonstrated economic viability and operational efficiency, achieving a rate of 8.57 images per minute, surpassing the manual method (3.33 images per minute). Second, usability tests of the web application, using the SUS scale, resulted in an average score of 76.2, indicating good user acceptance. Third, the platform integrated deep learning models for Human Visceral Leishmaniasis (based on InceptionV3) and Canine (based on YOLOv8) diagnosis, whose original studies report 98.7% F1-Score and 88.5% mAP, respectively. The results demonstrate that the proposed approach fulfills its objective, delivering an integrated tool that contributes to making the diagnosis of Leishmaniasis more accessible and efficient with capture automation, with the potential for implementation in endemic areas and expansion to other diseases.

Keywords: Automated diagnosis. Deep learning. Visceral leishmaniasis. Image capture. Digital microscopy.

Lista de ilustrações

Figura 1 – Imagem de microscopia evidenciando a presença de amastigotas (destacada pela seta preta) . . . 6
Figura 2 – Ciclo de transmissão da Leishmaniose, evidenciando a relação entre vetor, reservatório animal e hospedeiro humano. Imagem criada com BioRender <https://BioRender.com> 7
Figura 3 – Representação do processo de captura de imagens. . . . 13
Figura 4 – Projeto 3D do dispositivo de captura acoplada ao microscópio. . . . 14
Figura 5 – Dispositivo de captura acoplada ao microscópio. . . . 14
Figura 6 – Diagrama de Caso de Uso do sistema. . . . 18
Figura 7 – (A) Tela inicial na visão mobile (B) Visão Desktop. . . . 24
Figura 8 – Continuação da tela inicial do sistema, demonstrando o design responsivo com navegação por rolagem. . . . 24
Figura 9 – Interface de listagem das lâminas cadastradas com filtros por tipo de processamento e classificação de resultados. . . . 25
Figura 10 – Formulário para adição de nova lâmina com seleção de laboratório e tipo de análise. . 25
Figura 11 – Interface de detalhamento de lâmina do tipo humana, exibindo imagens processadas com classificações e percentuais de confiança. . . . 26
Figura 12 – Interface de detalhamento de lâmina do tipo canina. . . . 26
Figura 13 – Imagem microscópica original (A) com resultado da detecção das amastigotas em verde (B). . . . 27
Figura 14 – Modal de seleção entre submissão manual e captura automatizada de imagens para a lâmina. . . . 27
Figura 15 – Interface principal de gestão de laboratórios, disponível para superusuários e administradores de laboratório. . . . 28
Figura 16 – Tela de detalhamento do laboratório apresentando lista de participantes e suas respectivas funções. . . . 28
Figura 17 – Interface de gerenciamento de funções do laboratório, permitindo criação de papéis personalizados. . . . 29
Figura 18 – Interface de gerenciamento de convites com visualização de solicitações pendentes e criação de novos convites. . . . 29
Figura 19 – Email de convite recebido pelo usuário convidado, contendo link para aceitação do convite e criação de conta. . . . 30
Figura 20 – Solicitação de permissão do navegador para acesso à câmera do dispositivo. . . . 30
Figura 21 – Solicitação de permissão do navegador para acesso aos dispositivos USB conectados. . 31
Figura 22 – Interface inicial da captura automática com opções de configuração, captura e teste. . 31
Figura 23 – Configuração das dimensões da lâmina nas orientações horizontal e vertical para definição da área de captura. . . . 31
Figura 24 – Interface de configuração de parâmetros técnicos incluindo controles de foco, movimento e qualidade de imagem. . . . 32

Lista de tabelas

Tabela 1 – Comparação dos estudos relacionados à aplicação de *machine learning* na análise microscópica. 12
Tabela 2 – Custos aproximados dos componentes do dispositivo de captura. 15
Tabela 3 – Requisitos Funcionais. 15
Tabela 4 – Requisitos Não Funcionais. 16
Tabela 5 – Regras de Negócio. 17
Tabela 6 – Resultados da avaliação de usabilidade utilizando a escala SUS. 32

Lista de abreviaturas e siglas

AUC	Área sob a curva ROC (Receiver Operating Characteristic)
CDU	Classificação Decimal Universal
CSRF	Cross-Site Request Forgery
ELISA	Enzyme-Linked Immunosorbent Assay
IoU	Intersection over Union
IoT	Internet das Coisas
LV	Leishmaniose Visceral
MDF	Medium Density Fiberboard
MVT	Model-View-Template
OMS	Organização Mundial da Saúde
PPGCC	Programa de Pós-Graduação em Ciência da Computação
PETG	Polietileno Tereftalato Glicol
ROC	Receiver Operating Characteristic
RIFI	Reação de Imunofluorescência Indireta
SBCAS	Simpósio Brasileiro de Computação Aplicada à Saúde
SIG	Sistema Integrado de Gestão
SUS	System Usability Scale
SQL	Structured Query Language
U-Net	Arquitetura de Redes Neurais Convolucionais para Segmentação de Imagens
USB	Universal Serial Bus
XSS	Cross-Site Scripting

Sumário

1 INTRODUÇÃO 1
1.1 Problema 2
1.2 Objetivos 3
1.3 Contribuições 3
1.4 Publicações 3
1.5 Organização do Trabalho 4

2 REFERENCIAL TEÓRICO 5
2.1 Leishmaniose 5
2.2 Arduino 7
2.3 *Django Framework* 7
2.4 Banco de Dados *PostgreSQL* 8
2.5 Avaliação de Usabilidade 8
2.6 Aprendizado de Máquina em Visão Computacional 9
2.6.1 InceptionV3 10
2.6.2 YOLOv8 10

3 ESTADO DA ARTE 11
3.1 Considerações finais 12

4 METODOLOGIA 13
4.1 Modelagem e Desenvolvimento do Dispositivo de Captura 13
4.2 Análise dos Requisitos do Sistema 15
4.2.1 Requisitos Funcionais 15
4.2.2 Requisitos Não Funcionais 16
4.2.3 Regras de Negócio 16
4.3 Diagrama de Caso de Uso 17
4.4 Aplicação WEB e Servidor 18
4.5 Detecção de Amastigotas 20
4.5.1 Modelo para Leishmaniose Visceral Humana 20
4.5.2 Modelo para Leishmaniose Visceral Canina 21
4.6 Considerações Finais 21

5 RESULTADOS E DISCUSSÃO 23
5.1 Avaliação de Desempenho da Captura Automática 23
5.2 Construção da Aplicação WEB 23
5.3 Sistema de Gerenciamento de Laboratórios 26
5.3.1 Configuração e Captura Automática 28
5.4 Avaliação de Usabilidade do Sistema 30
5.5 Detecção de Amastigotas 32
5.6 Considerações Finais 33

6 CONCLUSÕES E TRABALHOS FUTUROS 35
6.1 Conclusões 35

6.2 Trabalhos Futuros 35

REFERÊNCIAS 37

1 Introdução

As Leishmanioses são um grupo de infecções protozoárias enzoóticas[1] e zoonóticas[2], classificadas como doenças tropicais negligenciadas (DTNs). Consideradas algumas das doenças infecciosas mais comuns, as DTNs englobam cerca de 20 infecções causadas por parasitas, bactérias, vírus, protozoários e helmintos[3]. Estudos de 2017 sobre a Carga Global de Doenças estimaram que as DTN foram responsáveis por 62 milhões de *Disability Adjusted Life Years* (DALYs), com 774.000 DALYs decorrentes da Leishmaniose, resultando em anos de vida perdidos devido à mortalidade prematura (WAMAI et al., 2020). A Organização Mundial da Saúde (OMS) estima a ocorrência de 700.000 a 1 milhão de novos casos anuais de Leishmaniose (LEISHMANIOSE, 2023).

Os protozoários do gênero *Leishmania*, agentes causadores das Leishmanioses, são patógenos intracelulares que invadem as células fagocitárias [4] do hospedeiro (SANTOS et al., 2023). Podem ser descritas aproximadamente 53 espécies de Leishmania, das quais 31 são parasitas de mamíferos e 20 são patogênicas aos seres humanos. As espécies podem causar duas manifestações clínicas principais, a Leishmaniose Tegumentar (LT)[5] e Visceral (LV) (AKHOUNDI et al., 2016). A transmissão ocorre por meio da picada de flebotomíneos [6] infectados , que ao se alimentarem do sangue do hospedeiro inoculam os protozoários presentes em suas glândulas salivares, permitindo a infecção e disseminação do parasita (CASTRO, 2023).

A LV é uma forma grave da doença, uma vez que detém cerca de 90% da carga de DALYs, e a doença é quase sempre fatal na ausência de tratamento (HOTEZ et al., 2014). Essa doença é frequentemente diagnosticada em cães, os quais atuam como reservatórios do parasita em áreas urbanas, aumentando o risco de transmissão aos humanos (CASTRO, 2023). A LV representa um desafio para a saúde pública no Brasil, entre 2007 e 2024, foram registrados 50.372 casos de Leishmaniose Visceral Humana (LVH), que resultaram em 3.944 óbitos e uma taxa de letalidade de 7,03%. Já no estado do Piauí, nesse mesmo período, a doença contabilizou 2.783 casos e 207 óbitos, com uma taxa de letalidade de 6,69% (SAÚDE, 2024).

Em humanos, a Leishmaniose caracteriza-se por um quadro clínico que pode evoluir ao longo de semanas a meses, apresentando sintomas como febre prolongada e irregular, perda de peso acentuada, além de aumento do baço (esplenomegalia) e do fígado (hepatomegalia), podendo ser fatal se não tratada (Organização Mundial da Saúde, 2023). Nos cães, a doença manifesta-se através de sinais como dermatite, úlceras cutâneas, anemia, alterações oculares, insuficiência renal, febre e linfadenopatia [7]. No entanto, muitos animais infectados permanecem assintomáticos, desempenhando ainda assim um papel fundamental na cadeia de transmissão do parasita para outros animais e para os seres humanos (KOUTINAS; KOUTINAS, 2014).

O diagnóstico da LV é realizado por meio de diferentes métodos, incluindo testes parasitológicos, sorológicos e moleculares. Entre esses, a detecção de anticorpos *antileishmania* por testes imunológicos,

---

1 Refere-se a uma enfermidade que afeta animais de forma constante em uma determinada região, análoga à endemia em humanos.
2 São aquelas que podem ser transmitidas entre animais e humanos
3 Termo que designa vermes parasitas.
4 Células do sistema imunológico, como os macrófagos, especializadas em destruir patógenos e detritos celulares.
5 Forma da doença que afeta a pele e as mucosas (tegumento), causando úlceras e lesões.
6 Insetos vetores responsáveis pela transmissão da Leishmania. A fêmea infectada transmite o protozoário ao se alimentar do sangue de um hospedeiro.
7 Linfadenopatia é o termo médico para o aumento dos linfonodos, que são pequenas estruturas do sistema linfático responsáveis por filtrar fluidos e combater infecções

como o *Enzyme Linked Immunosorbent Assay* (ELISA)[8] e a imunofluorescência indireta (RIFI)[9], são amplamente utilizados. No entanto, a acurácia desses testes pode variar dependendo do estágio da infecção, da resposta imunológica individual e das condições epidemiológicas da região. A baixa reprodutibilidade entre diferentes testes sorológicos pode comprometer a confiabilidade do diagnóstico, especialmente em indivíduos assintomáticos. Além disso, reações cruzadas com outros patógenos, como *Trypanosoma cruzi*[10] e *Plasmodium*[11] spp., podem resultar em falsos positivos, comprometendo a especificidade diagnóstica. Além disso, a positividade em testes sorológicos não indica necessariamente a progressão para a doença clínica, por essa razão, reforça-se a necessidade de abordagens complementares, como métodos moleculares e acompanhamento clínico, para uma avaliação mais precisa da infecção por Leishmaniose (SILVA et al., 2011).

Para o diagnóstico da LV, o diagnóstico parasitológico é o padrão-ouro. A microscopia de material aspirado, principalmente de medula óssea, é utilizada para a identificação de formas amastigotas[12] de *Leishmania* em esfregaços corados[13], sendo essencial examinar todos os campos da lâmina para aumentar a sensibilidade do exame. Estudos demonstram que a carga parasitária na medula óssea pode estar associada à gravidade da doença, sendo significativamente maior em pacientes com manifestações mais severas, como epistaxe (sangramento nasal), icterícia (coloração amarelada da pele e mucosas devido ao acúmulo de bilirrubina) e edema (inchaço causado pelo acúmulo de líquidos nos tecidos) (SILVA et al., 2014).

1.1 Problema

O diagnóstico precoce da LV em humanos e cães é fundamental para a eficácia do tratamento e para o controle da disseminação da doença, que tem os cães como principais reservatórios em áreas urbanas. Contudo, a complexidade do diagnóstico da LV representa um desafio para a saúde pública, especialmente em regiões endêmicas. O método de referência por microscopia, que consiste na identificação de formas amastigotas do parasita, é um processo manual, suscetível a erros humanos e demorado em relação a uma captura automatizada. A precisão desta análise depende diretamente da experiência do observador, o que pode levar a variações nos resultados e comprometer a acurácia diagnóstica (NEVES et al., 2014). Diante dessas limitações, o desenvolvimento de sistemas para auxiliar no diagnóstico é fundamental para mitigar a subjetividade e aumentar a eficiência do processo.

Estudos têm avançado no uso de algoritmos para auxiliar no diagnóstico da LV. O trabalho de Borges et al. (2024) desenvolveu algoritmos para identificação do parasita em lâminas de microscopia, contribuindo para a automação do diagnóstico da Leishmaniose Visceral Canina (LVC) e para o aprimoramento das estratégias de vigilância e controle. De forma semelhante, Goncalves et al. (2023) propuseram um método baseado em técnicas de *machine learning* para detecção de amastigotas, focando no diagnóstico de LVH. Entretanto, esses estudos não ofereceram um dispositivo de hardware para a captura automatizada de imagens, eles também não oferecem uma interface gráfica que permitisse aos usuários finais interagir diretamente com as ferramentas, limitando sua acessibilidade e praticidade para aplicação no contexto clínico.

[8] Técnica de laboratório comum (ensaio imunoenzimático) usada para detectar a presença de anticorpos ou antígenos numa amostra.
[9] Outra técnica laboratorial que utiliza anticorpos marcados com corantes fluorescentes para detectar a presença de anticorpos específicos na amostra do paciente.
[10] Protozoário causador da Doença de Chagas.
[11] Gênero de protozoários causadores da Malária. O 'spp.' indica que se refere a múltiplas espécies dentro desse gênero.
[12] Forma intracelular, não móvel (sem flagelo) e reprodutiva do parasita *Leishmania* que infecta as células do hospedeiro vertebrado (como humanos e cães). É o principal alvo buscado no diagnóstico microscópico.
[13] Técnica de preparação onde uma amostra biológica (como medula óssea ou sangue) é espalhada em uma camada fina sobre uma lâmina de vidro e tratada com corantes específicos para tornar as células e parasitas visíveis ao microscópio.

1.2 Objetivos

O objetivo geral deste trabalho é desenvolver uma aplicação WEB integrada a um sistema robótico de captura e análise de imagens microscópicas para auxiliar no diagnóstico da LV.

Os objetivos específicos deste trabalho são:

- Criar um dispositivo robótico para automatização de captura de imagens, diminuindo a necessidade de manipulação direta do microscópio;
- Propor um design de dispositivo de captura focado em baixo custo e componentes acessíveis, visando a produção em larga escala.
- Implementar uma interface WEB que permita aos usuários submeter imagens de lâminas de microscopia para análise;
- Integrar o dispositivo de captura com a aplicação WEB, permitindo o envio direto de imagens para análise automatizada;
- Integrar o sistema WEB proposto com modelos para diagnósticos da LVC e LVH.
- Avaliar a usabilidade da aplicação WEB por meio do questionário *System Usability Scale* (SUS).

1.3 Contribuições

As principais contribuições deste trabalho para a área de diagnóstico por imagem e saúde digital são:

- A construção de um dispositivo de captura de baixo custo: Um dispositivo robótico, baseado em impressão 3D e componentes acessíveis, que automatiza a varredura de lâminas microscópicas, demonstrando viabilidade econômica para implementação em laboratórios com recursos limitados.
- O desenvolvimento de um sistema integrado: Uma solução que unifica a captura automatizada de imagens, o processamento em nuvem e a análise por meio de uma interface web colaborativa.
- A implementação de uma abordagem de múltiplos modelos de IA: A integração de duas arquiteturas de *deep learning* distintas para LVH e LVC, oferecendo uma solução especializada e mais precisa para as diferentes necessidades diagnósticas.

1.4 Publicações

Os resultados parciais e a arquitetura desenvolvida no decorrer deste mestrado foram submetidos e aceitos para publicação em anais de congressos e simpósios de relevância nacional na área de Computação Aplicada à Saúde. As publicações decorrentes deste trabalho são:

- **Sistema Web para Classificação de Leishmaniose Visceral com Coleta de Imagem Microscópicas Automática.**
  Autores: Souza, L. B. M. de; Borges, A. L.; Dias, V. B. L.; Gonçalves, C. de A.; Viana, D. de A.; Pacheco, A. C. L.; Silva, R. R. V. e.
  Publicado em: Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS), 2024.

- **Detecção Automática de Macrófagos em Exame Parasitológico Utilizando Clusterização e Redes Neurais Convolucionais.**
  Autores: Borges, A. L.; Dias, V. B. L.; Gonçalves, C. de A.; Souza, L. B. M. de; Viana, D. de A.; Pacheco, A. C. L.; Silva, R. R. V. e.
  Publicado em: Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS), 2024.

- **Introdução à Robótica e Eletrônica Básica com Arduino.**
  Autores: Souza, L. B. M. de; Dias, K. S.; Barreto, C. R. G.; Silva, R. R. V. e.
  Publicado em: Anais do XIII Simpósio de Sistemas de Informação (SINFO), 2024.

- **Sistema WEB para Diagnóstico Automatizado por Imagem com Suporte a Diferentes Modelos de Classificação Microscópica.**
  Autores: Souza, L. B. M. de; Dias, K. S.; Borges, A. L.; Dias, V. B. L.; Gonçalves, C. de A.; Araújo, R. L.; Sátiro, C. E. S.; Pacheco, A. C. L.; Silva, R. R. V. e.
  Publicado em: Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS), 2025.

- **Detecção Automática de Macrófagos em Esfregaço de Medula Óssea Canina com Deep Learning.**
  Autores: Araújo, R. L.; Dias, V. B. L.; Borges, A. L.; Souza, L. B. M. de; Dias, K. S.; Sátiro, C. E. S.; Gonçalves, C. de A.; Pacheco, A. C. L.; Silva, R. R. V. e.
  Publicado em: Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS), 2025.

- **Machine Learning no Diagnóstico Parasitológico Direto de Leishmaniose Visceral: Uma Revisão.**
  Autores: Dias, V. B. L.; Sátiro, C. E. S.; Borges, A. L.; Dias, K. S.; Araújo, R. L.; Souza, L. B. M. de; Gonçalves, C. de A.; Pacheco, A. C. L.; Silva, R. R. V. e.
  Publicado em: Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS), 2025.

- **Detecção de Amastigotas de Leishmaniose Visceral em Imagens Microscópicas utilizando Redes Neurais Convolucionais.**
  Autores: Souza, L. B. M. de; Dias, K. S.; Dias, V. B. L.; Sátiro, E. S.; Borges, A. L.; Gonçalves, C. de A.; Araújo, R. L.; Pacheco, A. C. L.; Silva, R. R. V. e.
  Submetido em: Revista de Sistemas e Computação, 2025.

1.5 Organização do Trabalho

Este trabalho está estruturado em seis capítulos. O **Capítulo 1** apresenta a introdução, contextualizando o problema, os objetivos, as contribuições da pesquisa, as publicações resultantes e a organização do documento. O **Capítulo 2** detalha o referencial teórico que fundamenta o estudo, abordando conceitos sobre a Leishmaniose e as principais tecnologias utilizadas. O **Capítulo 3** revisa o estado da arte, analisando trabalhos correlatos na área de diagnóstico automatizado.

O **Capítulo 4** descreve a metodologia, incluindo a modelagem e o desenvolvimento do dispositivo de captura, a análise de requisitos do sistema, a arquitetura da aplicação web e os detalhes dos modelos de detecção de amastigotas. O **Capítulo 5** apresenta e discute os resultados obtidos, abordando a avaliação de desempenho da captura automática, a construção da aplicação web, a avaliação de usabilidade e os resultados da detecção de amastigotas pelos modelos de dos modelos de *machine learning*. Finalmente, o **Capítulo 6** apresenta as conclusões do trabalho e aponta direções para pesquisas futuras.

2 Referencial Teórico

Nessa seção serão detalhados os tópicos necessários para a compreensão das técnicas e ferramentas utilizadas no método proposto, além de pontos importantes que levaram o desenvolvimento desse estudo. Serão abordados: Leishmaniose 2.1, Arduino (2.2), *Django Framework* (2.3), Banco de Dados *PostgreSQL* 2.4, Avaliação de Usabilidade (2.5) e Aprendizado de Máquina em Visão Computacional (2.6)

2.1 Leishmaniose

A Leishmaniose Visceral é uma doença infecciosa causada por protozoários do gênero *Leishmania*, que são transmitidos aos hospedeiros vertebrados através da picada de insetos flebotomíneos. Esses parasitas possuem um ciclo de vida heteroxeno (precisam de mais de um hospedeiro para completar o seu ciclo de vida), alternando entre a forma promastigota[1], presente no vetor invertebrado, e a forma amastigota, que se desenvolve no hospedeiro vertebrado. A doença pode se manifestar em diferentes formas clínicas, sendo as LV a mais grave e potencialmente fatal se não tratada (RIOS et al., 2022).

A forma amastigota da *Leishmania* é a principal responsável pelo estabelecimento da infecção no organismo do hospedeiro vertebrado. Esses parasitas são intracelulares obrigatórios e se multiplicam no interior dos macrófagos[2], células do sistema imunológico responsáveis pela fagocitose. Durante esse processo, a *Leishmania* consegue modular a resposta imunológica do hospedeiro, evitando sua eliminação e favorecendo a progressão da infecção. A persistência da forma amastigota nos tecidos do hospedeiro está associada a um estado de imunossupressão, o que permite a disseminação sistêmica do parasita (RIOS et al., 2022). A Figura 1 mostra uma amastigota dispersa no citoplasma do macrófago.

A transmissão da Leishmaniose ocorre quando um flebotomíneo fêmea infectado realiza o repasto sanguíneo[3] em um hospedeiro vertebrado, inoculando formas promastigotas na pele. Essas formas são rapidamente ingeridas por macrófagos, onde se diferenciam em amastigotas e iniciam sua replicação intracelular. Com a destruição do macrófago, novos parasitas são liberados, infectando outras células e espalhando a infecção (BACETTI et al., 2021).

Os principais reservatórios do parasita incluem cães domésticos, raposas e roedores, que atuam como fonte de infecção para os flebotomíneos. Ao se alimentar do sangue desses animais, o vetor ingere amastigotas, que no intestino médio do inseto diferenciam-se em promastigotas imaturas. Essas formas multiplicam-se ativamente, tornando-se promastigotas infectantes, que migram para a probóscide[4] do inseto e ficam prontas para uma nova transmissão (MEDEIROS; NEGREIROS, 2022). A Figura 2 ilustra esse ciclo biológico da Leishmaniose, destacando a interação entre o vetor, os reservatórios e o hospedeiro humano.

Os macrófagos são essenciais na resposta imunológica contra infecções, atuando na fagocitose de patógenos e na ativação de outros componentes do sistema imune. No entanto, na Leishmaniose, essas células acabam servindo como reservatórios do parasita, permitindo sua sobrevivência e replicação no ambiente intracelular. A *Leishmania* contorna o sistema imunológico ao inibir a produção de óxido nítrico e outras moléculas microbicidas, tornando a resposta do hospedeiro ineficaz contra a infecção (SOUZA,

[1] Forma móvel (flagelada) e infecciosa do parasita, encontrada no trato digestivo do inseto vetor (flebotomíneo) e inoculada no hospedeiro durante a picada.
[2] Tipo de célula de defesa (glóbulo branco) do sistema imunológico, cuja função principal é a fagocitose (limpeza) de detritos celulares, patógenos e outras células mortas.
[3] Termo técnico para o ato de um vetor (como um inseto) se alimentar do sangue de um hospedeiro.
[4] Aparelho bucal alongado e tubular de certos insetos, adaptado para sugar líquidos, como sangue ou néctar.

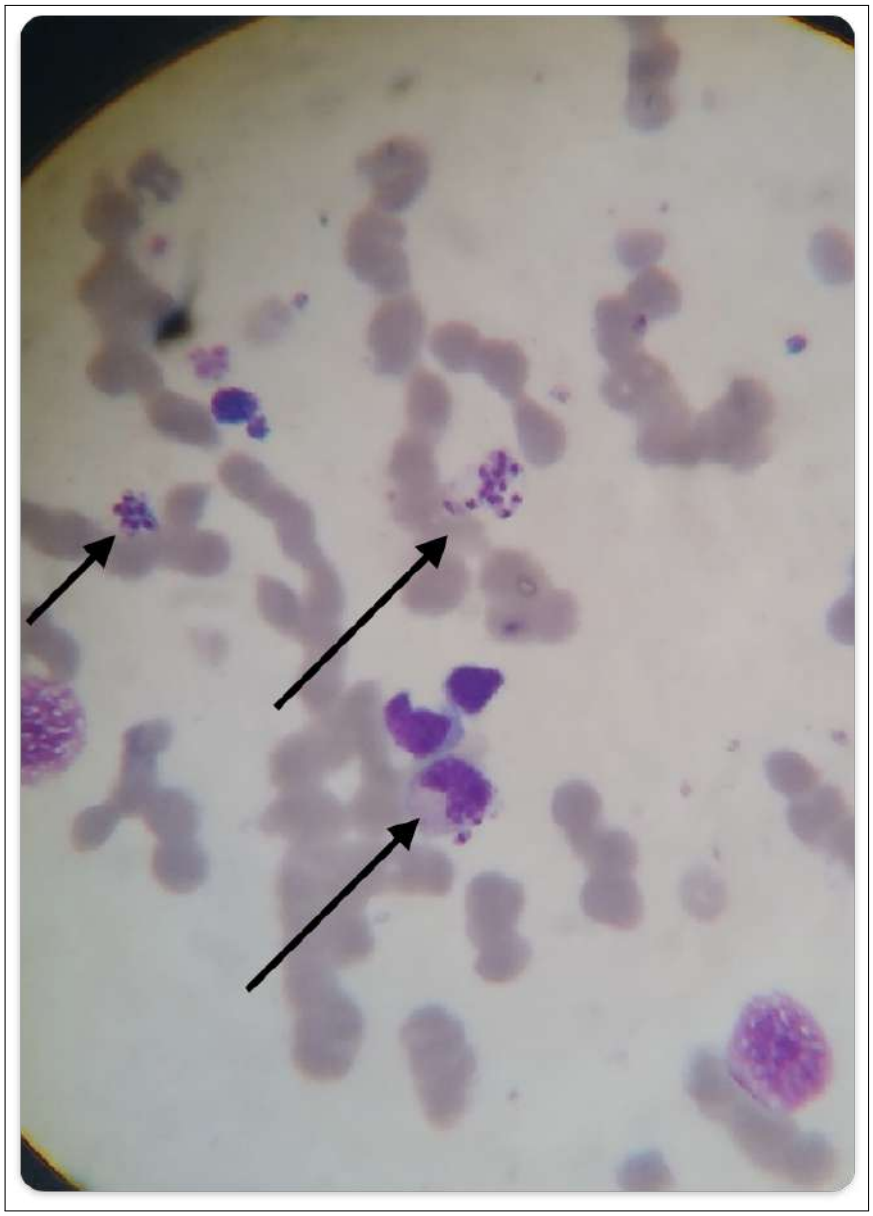


Figura 1 – Imagem de microscopia evidenciando a presença de amastigotas (destacada pela seta preta)

2012). Além disso, as amastigotas podem ativamente internalizar e degradar as moléculas de MHC de classe II[5] do macrófago, um mecanismo que impede a célula de alertar outros componentes do sistema imune, e assim, subverte a resposta imune adaptativa (LEAO et al., 1995).

O diagnóstico da LV por análise microscópica de amostras biológicas, como medula óssea, envolve uma coleta dessas amostras e é um procedimento que deve ser realizado por profissionais capacitados. Após a coleta, o material é submetido a técnicas de coloração, comumente utilizada a coloração de Giemsa[6] para facilitar a visualização dos parasitas. As lâminas preparadas são então analisadas manualmente sob microscópio óptico, onde o especialista busca identificar a presença das formas amastigotas do protozoário no interior dos macrófagos (SOUZA, 2019).

[5] A sigla MHC (do inglês, *Major Histocompatibility Complex*) refere-se a proteínas na superfície das células imunes que apresentam fragmentos de patógenos para outras células de defesa (linfócitos T), ativando a resposta imune adaptativa.

[6] Um tipo específico de corante histológico usado para identificar parasitas sanguíneos (como *Leishmania* e *Plasmodium*), pois confere uma cor roxa característica ao núcleo e outras estruturas celulares.

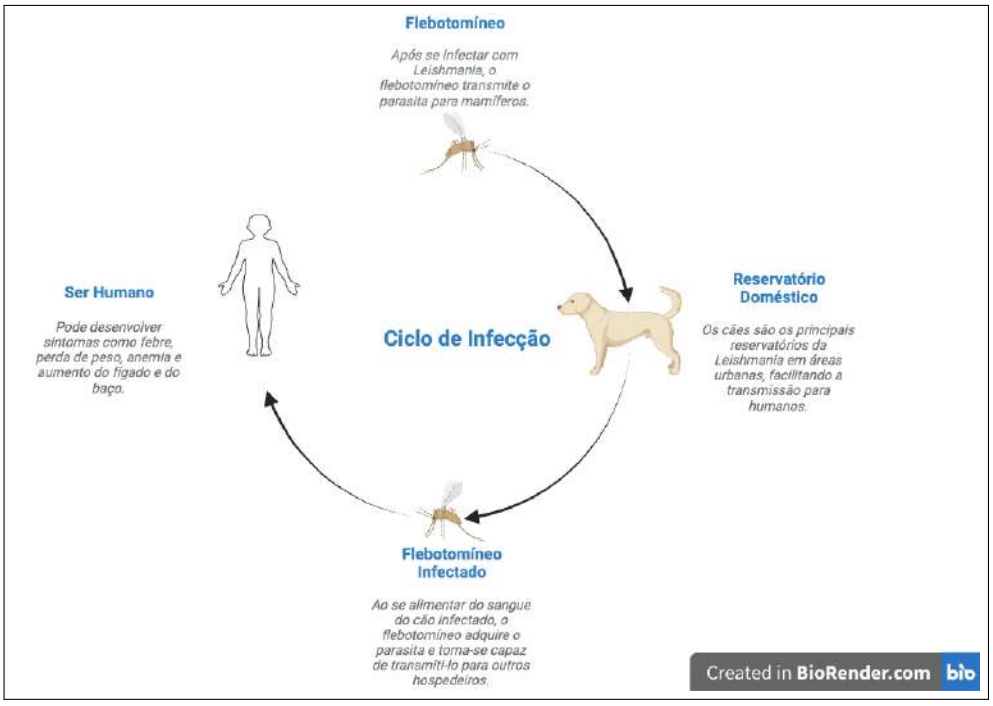


Figura 2 – Ciclo de transmissão da Leishmaniose, evidenciando a relação entre vetor, reservatório animal e hospedeiro humano. Imagem criada com BioRender <https://BioRender.com>

2.2 Arduino

O Arduino é uma plataforma *open-source* de hardware e software projetada para facilitar o desenvolvimento de projetos de eletrônica e automação. Criado na Itália em 2005 por um grupo de pesquisadores liderados por Massimo Banzi, o Arduino se popularizou rapidamente devido à sua simplicidade e versatilidade. Ele é composto por uma placa eletrônica programável e um ambiente de desenvolvimento integrado (IDE), que permite a escrita e o upload de códigos para o microcontrolador presente na placa (ARDUINO, 2024).

A utilização do Arduino possibilita a implementação de soluções para automação de tarefas em diversos contextos, incluindo automação residencial, controle de dispositivos eletrônicos, robótica e monitoramento ambiental. A programação baseada em *C/C++* e a compatibilidade com uma ampla variedade de sensores e módulos permitem a criação de sistemas que executam ações de forma autônoma, reduzindo a necessidade de intervenção manual (MONTIRONI; QIAN; CHENG, 2017).

O Arduino tem sido adotado em instituições de ensino para auxiliar no ensino tanto de programação como de outras áreas (MOREIRA et al., 2018). Além de ser empregado em pesquisas científicas e projetos industriais. Sua capacidade de interface com a Internet das Coisas (IoT) também impulsionou sua utilização em soluções inovadoras, permitindo a conexão de dispositivos e a automação de processos em tempo real. Dessa forma, o Arduino se consolidou como uma das principais plataformas para o desenvolvimento de circuitos compactos e robustos.

2.3 *Django Framework*

O *Django* (DJANGO, 2025) é um *framework* WEB de alto nível escrito em *Python*, amplamente utilizado para o desenvolvimento de aplicações WEB robustas, escaláveis e seguras. Criado para agilizar o processo de desenvolvimento, ele oferece um conjunto abrangente de ferramentas e recursos pré-construídos, incluindo sistema de autenticação, administração de conteúdo, manipulação de formulários e gerenciamento

de banco de dados, permitindo que os desenvolvedores foquem na lógica da aplicação sem precisar reinventar funcionalidades essenciais (VAMSI et al., 2021).

Um dos principais diferenciais do Django é a sua segurança integrada, prevenindo ataques comuns, como injeção de *Structured Query Language* (SQL), *Cross-Site Scripting* (XSS) e *Cross-Site Request Forgery* (CSRF). Além disso, sua estrutura baseada no padrão *Model-View-Template* (MVT) facilita a organização do código, promovendo um desenvolvimento modular e reutilizável (DJANGO, 2025).

No contexto de aplicações biomédicas, o *Django* se destaca como uma escolha eficiente para a criação de plataformas WEB interativas, possibilitando a integração de sistemas de processamento e análise de imagens médicas. Por ser construído em *Python*, a *framework* tem compatibilidade com bibliotecas de aprendizado de máquina e visão computacional da linguagem, como *TensorFlow* e *OpenCV*, permite a implementação de soluções para suporte ao diagnóstico, como no caso da detecção automatizada de *Leishmaniose* em imagens microscópicas.

Além da sua robustez técnica, o *Django* conta com uma comunidade ativa e extensa documentação, o que facilita o aprendizado e a resolução de problemas. Sua adoção por grandes empresas e instituições demonstra sua confiabilidade e versatilidade, tornando-o uma excelente escolha para aplicações WEB que exigem desempenho, segurança e escalabilidade.

2.4 Banco de Dados *PostgreSQL*

O PostgreSQL (POSTGRESQL, 2025) é um sistema de gerenciamento de banco de dados relacional de código aberto, reconhecido por sua escalabilidade, flexibilidade e capacidade de lidar com diferentes tipos de dados. Desde sua primeira versão em 1996, tem sido utilizado em diversos setores, incluindo aplicações comerciais, governamentais e acadêmicas, devido à sua estabilidade e desempenho consistente.

Pesquisas científicas têm analisado a eficiência do PostgreSQL em diferentes cenários. Um estudo conduzido por Purohit (2018) comparou seu desempenho com outros sistemas de gerenciamento de banco de dados, demonstrando sua adequação para aplicações que exigem alta disponibilidade e escalabilidade.

O PostgreSQL é reconhecido por sua capacidade de gerenciar grandes volumes de dados de maneira eficiente, sendo aprimorado por uma comunidade ativa de desenvolvedores. Seus recursos avançados e otimização de desempenho o tornam uma escolha frequente para diversas aplicações (UAMBA, 2024).

2.5 Avaliação de Usabilidade

O *System Usability Scale* (SUS) (BROOKE, 1986) é um método padronizado para avaliar a usabilidade de um sistema. Trata-se de um questionário composto por dez afirmações, respondidas em uma escala de 1 a 5, onde 1 representa “discordo completamente” e 5 significa “concordo completamente”. Esse instrumento pode ser aplicado em diversos contextos, incluindo softwares, websites, aplicativos e outras interfaces interativas (TEIXEIRA, 2015).

A escala foi desenvolvida por *John Brooke* em 1986, visando fornecer uma métrica simples para avaliar a usabilidade percebida pelos usuários. O SUS mede três dimensões principais: eficácia, eficiência e satisfação. A eficácia está relacionada à capacidade do usuário de realizar tarefas dentro do sistema, a eficiência refere-se ao esforço necessário para completar essas tarefas e a satisfação avalia o conforto e aceitação da interface pelo usuário (BARROS, 2022).

O questionário é composto pelas seguintes afirmações:

1. Eu acho que gostaria de usar este sistema frequentemente.

2. Eu acho o sistema desnecessariamente complexo.
3. Eu achei o sistema fácil de usar.
4. Eu acho que precisaria de ajuda técnica para utilizar o sistema.
5. Eu acho que as várias funções do sistema estão bem integradas.
6. Eu acho que o sistema apresenta muitas inconsistências.
7. Eu imagino que as pessoas aprenderiam rapidamente a utilizar este sistema.
8. Eu achei o sistema confuso de usar.
9. Eu me senti confiante ao usar o sistema.
10. Eu precisei aprender várias coisas novas antes de conseguir utilizar o sistema.

Para calcular a pontuação SUS, aplica-se a seguinte metodologia:

- Para cada item ímpar (1, 3, 5, 7, 9), subtrai-se 1 do valor da resposta.
- Para cada item par (2, 4, 6, 8, 10), subtrai-se o valor da resposta de 5.
- A soma dos valores ajustados é multiplicada por 2,5 para obter a pontuação final do SUS, que varia entre 0 e 100.

A interpretação dos resultados pode ser feita comparando-se a pontuação obtida com valores de referência. A média geral do SUS é de aproximadamente 68, sendo que valores acima desse indicam boa usabilidade, enquanto valores abaixo sugerem possíveis problemas.

2.6 Aprendizado de Máquina em Visão Computacional

O Aprendizado de Máquina (*Machine Learning*) é um campo da ciência da computação que confere aos sistemas a capacidade de aprender a partir de dados, sem serem explicitamente programados. Os algoritmos são treinados para identificar padrões em grandes conjuntos de dados e, a partir deles, fazer predições ou tomar decisões (BISHOP, 2006).

Uma subárea importante é o Aprendizado Profundo (*Deep Learning*), que utiliza Redes Neurais Artificiais com múltiplas camadas (profundas) para modelar e compreender padrões. Essa abordagem tem se mostrado bastantes usada em Visão Computacional, pois as camadas da rede conseguem aprender hierarquias de características visuais, desde bordas simples até formas complexas, diretamente dos pixels das imagens (GOODFELLOW; BENGIO; COURVILLE, 2016).

Para treinar modelos de *deep learning* com bancos de imagens limitados pode ser utilizado algumas técnicas como a transferência de aprendizado (*transfer learning*) e o aumento de dados (*data augmentation*). Ela permite que um modelo pré-treinado em um vasto conjunto de dados genéricos, como o ImageNet, seja reaproveitado como ponto de partida. O conhecimento adquirido nesse treinamento inicial é, então, ajustado (*fine-tuned*) para a tarefa específica, o que reduz significativamente o tempo de treinamento e a necessidade de dados (HUSSAIN et al., 2019). Complementarmente, *data augmentation* é uma estratégia para expandir artificialmente o conjunto de treinamento, aplicando transformações aleatórias nas imagens existentes (como rotações, zooms e espelhamentos) para criar novas amostras,

tornando o modelo mais robusto a variações e menos propenso a sobreajuste (*overfitting*) (SHORTEN; KHOSHGOFTAAR, 2019).

As técnicas de *transfer learning* são frequentemente aplicadas a arquiteturas de Redes Neurais Convolucionais (CNNs) que se tornaram fundamentais na área. Dentre os diversos modelos propostos na literatura, este trabalho utilizou duas abordagens proeminentes que se beneficiam dessa técnica: a arquitetura InceptionV3 (SZEGEDY et al., 2016), focada na classificação de imagens, e o modelo YOLOv8 (JOCHER; CHAURASIA; QIU, 2023), focado na detecção de objetos.

2.6.1 InceptionV3

Uma arquitetura de *Deep Learning* proeminente para classificação de imagens é a InceptionV3. Proposta originalmente por Szegedy et al. (2016), esta rede faz parte da família de modelos *Inception* do Google. Sua principal inovação foi o aprimoramento do módulo *Inception*, que aplica filtros convolucionais de diferentes tamanhos (como 1x1, 3x3 e 5x5) em paralelo e concatena seus resultados. A versão V3 introduziu melhorias, como a fatorização de convoluções maiores (por exemplo, substituindo uma convolução 7x7 por duas 3x3), o que reduz drasticamente o número de parâmetros e o custo computacional, aumentando a eficiência do modelo sem sacrificar a precisão.

2.6.2 YOLOv8

Para a tarefa de detecção de objetos em tempo real, a família de modelos YOLO (*You Only Look Once*) é amplamente utilizada. O YOLOv8 é a iteração mais recente desenvolvida pela *Ultralytics*. Diferente dos classificadores, as arquiteturas YOLO tratam a detecção de objetos como um problema de regressão. Elas analisam a imagem uma única vez e preveem, de forma direta, as coordenadas das caixas delimitadoras (*bounding boxes*) e as probabilidades de classe para múltiplos objetos. O YOLOv8 se destaca por sua alta performance, eficiência computacional e arquitetura flexível, que permite permite sua aplicação tanto para detecção quanto para segmentação

3 Estado da Arte

Este capítulo apresenta o estado da arte em pesquisas que fundamentam este trabalho, com foco na automação do diagnóstico da Leishmaniose Visceral. A análise se concentra na aplicação de *machine learning* na análise microscópica e no desenvolvimento de sistemas automatizados para a captura de imagens.

Goncalves et al. (2023) desenvolveram um método baseado em *deep learning* para detectar parasitas da LVH em imagens de microscopia de medula óssea. Utilizando a arquitetura U-Net para segmentação, o modelo alcançou uma precisão de 99,1%, com um Dice de 80,4% e uma IoU de 75,2%, demonstrando a viabilidade do uso de inteligência artificial para auxiliar especialistas no diagnóstico da doença. Os resultados indicam que a automação desse processo pode reduzir o tempo de análise e minimizar erros humanos, tornando o diagnóstico mais eficiente e acessível.

Zare et al. (2022) desenvolveram um sistema baseado em inteligência artificial para a detecção automática de Leishmaniose em imagens microscópicas, utilizando o algoritmo Viola-Jones (VIOLA; JONES, 2001) aprimorado pelo método AdaBoost (FREUND; SCHAPIRE, 1997). O estudo demonstrou que o sistema obteve uma sensibilidade de 83% na detecção de macrófagos infectados e 71% na identificação de amastigotas, enquanto a especificidade foi de 65% e 52%, respectivamente. Embora a abordagem tenha se mostrado promissora para a automatização da análise microscópica, os resultados indicam que o modelo ainda apresenta limitações na redução de falsos positivos e negativos.

O trabalho de Oliveira et al. (2024) propõe um sistema de microscopia óptica automatizado e de baixo custo, voltado para laboratórios com poucos recursos. Utilizando um protótipo impresso em 3D, motores servo controlados por *Arduino* e um *smartphone* para captura de imagens, a solução permite a movimentação automatizada da lâmina e o foco automático. Sua principal inovação está na combinação dessa automação com redes neurais convolucionais para diagnóstico baseado em imagem, tornando-a adaptável a diferentes microscópios convencionais e com potencial para implementação em larga escala. No entanto, a dependência do *smartphone* adiciona complexidade e limitações, como a variabilidade na qualidade das câmeras e a necessidade de um dispositivo compatível, fatores que podem comprometer a padronização dos resultados e dificultar sua adoção em ambientes com poucos recursos.

Ward et al. (2022) desenvolveram um sistema baseado em inteligência artificial para a detecção automatizada de ovos de helmintos transmitidos pelo solo e *Schistosoma mansoni* em esfregaços fecais. O estudo utilizou um *scanner* de imagens de lâminas, cujo custo elevado (1.587 euros) representa um desafio para sua ampla implementação em regiões de baixa renda. O sistema emprega um modelo de detecção baseado em redes neurais convolucionais, R-FCN ResNet101 (LARSSON; HEDBERG, 2020), apresentou uma precisão média ponderada de 94,9% e um *recall* de 96,1%. Embora a pesquisa tenha demonstrado a viabilidade da patologia digital assistida por inteligência artificial para doenças tropicais negligenciadas, desafios técnicos e financeiros ainda precisam ser superados antes da implementação clínica em larga escala, especialmente no que diz respeito à automação completa da varredura das lâminas e à otimização da sensibilidade e especificidade diagnóstica.

Maturana et al. (2022) revisaram os avanços e desafios na automação do diagnóstico de malária utilizando microscopia digital com ferramentas de inteligência artificial. O estudo destaca a utilização de redes neurais convolucionais para a detecção de parasitas da malária, permitindo a automatização do processo de análise de esfregaços sanguíneos. O uso de *smartphones* para captura de imagens e software de identificação de parasitas é uma opção viável para diagnósticos em regiões de poucos recursos, mas ainda

enfrenta desafios relacionados à automação completa do foco e movimentação das lâminas. Além disso, o estudo enfatiza a necessidade de padronização dos protocolos de aquisição de imagens para garantir a confiabilidade dos modelos de inteligência artificial na identificação dos parasitas.

3.1 Considerações finais

A Tabela 1 apresenta uma comparação entre os estudos relacionados a este trabalho, destacando diferentes abordagens e técnicas para o diagnóstico automatizado de doenças por meio de métodos de inteligência artificial. Os estudos analisados demonstram o potencial dessas tecnologias para otimizar a análise microscópica e reduzir o tempo do diagnóstico. No entanto, ainda existem desafios relacionados à implementação prática, padronização e acessibilidade das soluções.

Estudo	**Foco**	**Técnicas Usadas**	**Resultados**
Zare et al. (2022)	Leishmaniose	Aprendizado de máquina (Viola-Jones, AdaBoost)	Sensibilidade de 83%, desafios na redução de falsos positivos
Ward et al. (2022)	Diagnóstico de helmintos	R-FCN ResNet101	Precisão de 94,9%, custo elevado como barreira
Maturana et al. (2022)	Diagnóstico de malária	Redes neurais convolucionais	Uso de *smartphones*, desafios na automação do foco
Goncalves et al. (2023)	LV	Aprendizado profundo (U-Net)	Precisão de 99,1%, desafios na implementação prática
Oliveira et al. (2024)	Microscopia automatizada	Hardware de baixo custo + CNNs	Solução acessível e adaptável, desafios na padronização das imagens

Tabela 1 – Comparação dos estudos relacionados à aplicação de *machine learning* na análise microscópica.

A análise dos trabalhos correlatos, resumida na Tabela 1, revela lacunas importantes que este trabalho busca endereçar. Existem soluções focadas exclusivamente em algoritmos, como a de Goncalves et al. (2023), que propõem modelos de *deep learning* eficazes para LV, mas não oferecem o *hardware* para automatizar a aquisição de imagens ou softwares para o usuário final utilizar esses modelos. Por outro lado, existem sistemas de *hardware* de alto custo, como o *scanner* utilizado por Ward et al. (2022), que inviabilizam a implementação em laboratórios com recursos limitados. Finalmente, há uma categoria de protótipos de *hardware* de baixo custo, como os de Maturana et al. (2022) e Oliveira et al. (2024), que validam o uso de impressão 3D e Arduino.

Embora esta última categoria seja a que mais se aproxima da presente proposta, ela é predominantemente baseada no uso de *smartphones* para controle e captura de imagens. Esta dependência introduz desafios significativos de padronização, como a variabilidade na qualidade das câmeras, e limita a capacidade de processamento e gerenciamento de dados.

Diante desse cenário, este trabalho se diferencia ao propor uma solução integrada que vai desde o *hardware* para captura de imagens ao software de gestão integrado com modelos de *deep learning*. Como contribuição principal, este trabalho apresenta um sistema que utiliza um dispositivo de captura de baixo custo com uma câmera USB dedicada, garantindo maior padronização na aquisição das imagens, e também o integra diretamente a uma plataforma WEB escalável. Esta plataforma gerencia o processamento assíncrono em nuvem e fornece uma interface colaborativa para o gerenciamento de laboratórios, superando as limitações de padronização e de integração de *software* identificadas nos estudos anteriores.

4 Metodologia

Esta seção descreve a metodologia e arquitetura do projeto desenvolvido. A Figura 3 apresenta o fluxo de processamento do sistema desenvolvido para a análise de imagens microscópicas de *Leishmania*. O processo inicia-se com a aquisição das imagens a partir do dispositivo de captura acoplado a um microscópio ou submissão manual, em seguida as imagens são processadas no servidor, onde os modelos cadastrados no sistema, InceptionV3 e YOLOv8, realizam a detecção para determinar a presença de amastigotas nas imagens de lâmina humana ou canina. As etapas da metodologia incluem: Modelagem e Desenvolvimento do Dispositivo de Captura (4.5), Análise dos Requisitos do Sistema (4.2), Diagrama de Caso de Uso (4.3), Aplicação WEB e Servidor (4.1) e Detecção de Amastigotas (4.5)

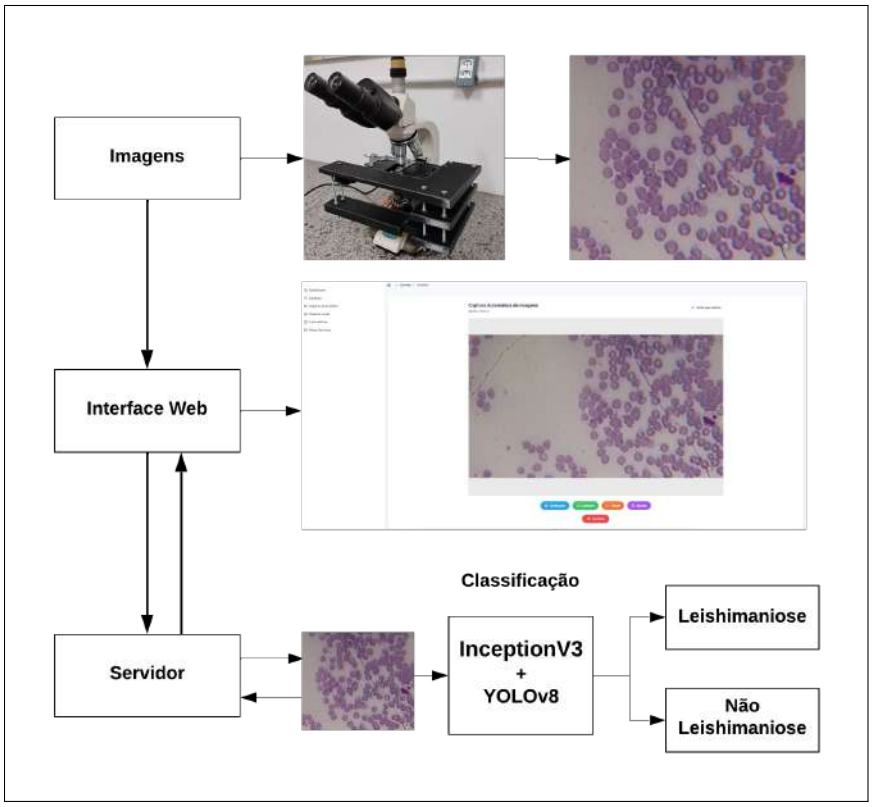


Figura 3 – Representação do processo de captura de imagens.

4.1 Modelagem e Desenvolvimento do Dispositivo de Captura

Para obtenção automatizada de imagens microscópicas, foi desenvolvido um dispositivo de captura composto de *Polietileno Tereftalato Glicol* (PETG) modelados por meio de impressão 3D (Figura 4). A movimentação precisa da lâmina é realizada por dois motores de passo acoplados ao microscópio, permitindo controle bidimensional dos deslocamentos com precisão. A Figura 5 apresenta os principais componentes do dispositivo, incluindo a estrutura de fixação no microscópio e o conjunto de engrenagens responsáveis pela movimentação da lâmina.

O dispositivo de captura foi projetada para ser uma solução de baixo custo, a Tabela 2 apresenta estimativa dos custos dos componentes utilizados na construção do dispositivo, cotados em 2025, demonstrando a viabilidade econômica da solução proposta para implementação em laboratórios com recursos

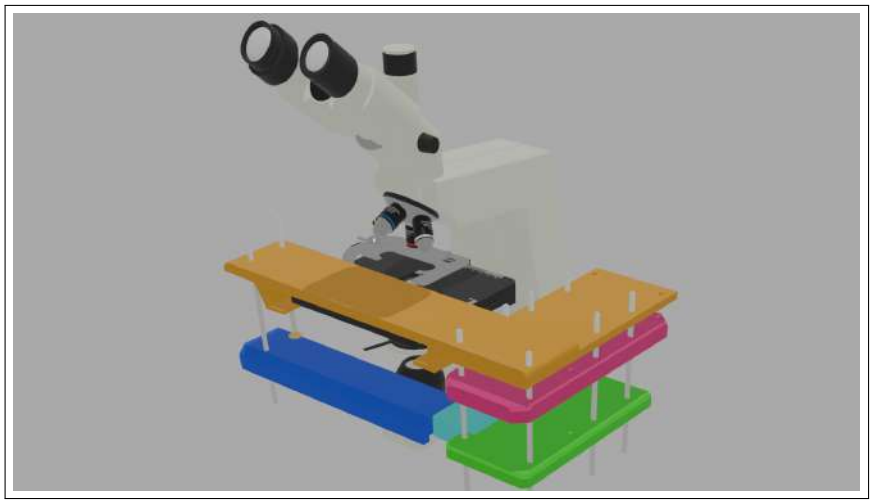


Figura 4 – Projeto 3D do dispositivo de captura acoplada ao microscópio.

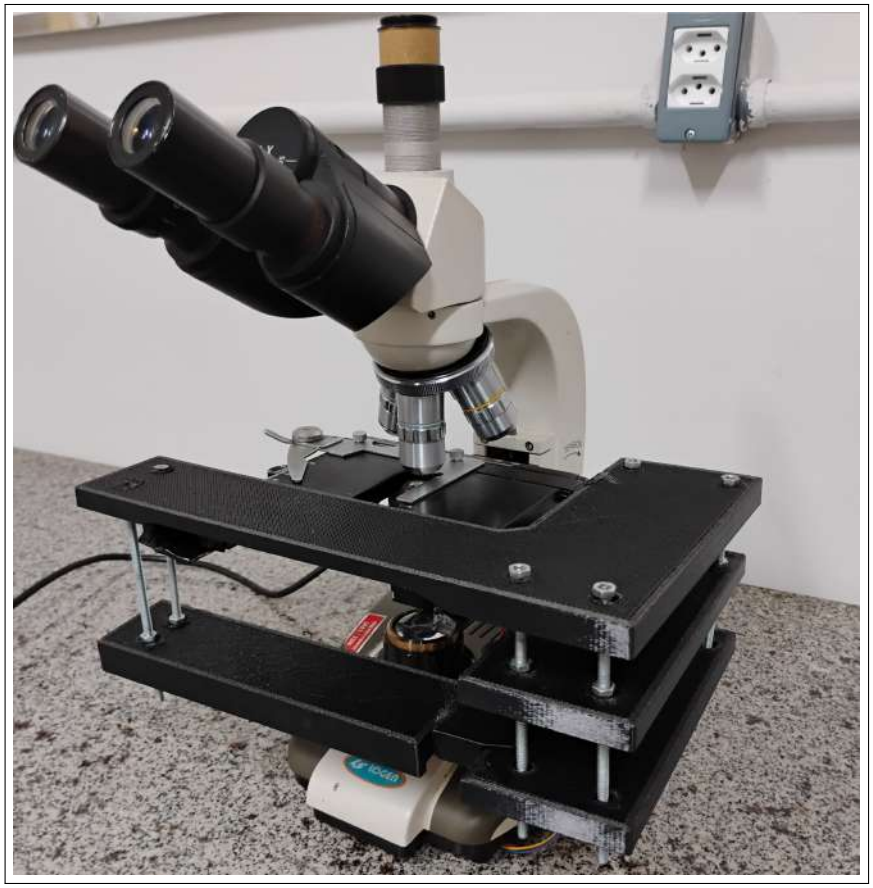


Figura 5 – Dispositivo de captura acoplada ao microscópio.

limitados.

A automação é gerenciada por um microcontrolador *Arduino*, responsável por coordenar os motores e definir os pontos de captura. A aquisição das imagens é feita por uma câmera USB de alta resolução (1920 × 1080), garantindo qualidade na análise. O dispositivo permite ajustar a posição inicial e final da lâmina, bem como o tamanho dos passos do motor, otimizando a captura das regiões de interesse.

Componente	Preço Aproximado (R$)
Câmera	150,00
Impressão 3D	95,00
Dois motores de passo	40,00
Microcontrolador	20,00

Tabela 2 – Custos aproximados dos componentes do dispositivo de captura.

4.2 Análise dos Requisitos do Sistema

Os requisitos do sistema foram definidos a partir de um estudo conduzido pelo grupo de pesquisa responsável pelo desenvolvimento da solução. Durante esse processo, foram consideradas as necessidades técnicas e operacionais do sistema, com ênfase na automação da captura de imagens microscópicas e na análise de parasitas. A definição desses requisitos contou com a colaboração de profissionais da área de Tecnologia da Informação, de uma especialista em Biologia e de um veterinário, cuja especialidade foi fundamental para a identificação e caracterização da Leishmaniose em exames microscópicos.

O sistema desenvolvido possui requisitos que definem suas funcionalidades principais e especificações técnicas para detecção automatizada de *Leishmania* em imagens microscópicas. Esses requisitos são classificados em três categorias: requisitos funcionais, que descrevem as operações essenciais do sistema e do dispositivo de captura; requisitos não funcionais, que estabelecem critérios de desempenho, segurança e acessibilidade; e regras de negócio, que delimitam as permissões e restrições para o uso do sistema.

4.2.1 Requisitos Funcionais

Os requisitos funcionais estabelecem as funcionalidades essenciais que devem ser implementadas para que o sistema atenda aos seus objetivos. Estes requisitos garantem que a aplicação seja capaz de processar imagens microscópicas, detectar parasitas e permitir o gerenciamento dos diagnósticos gerados. A Tabela 3 apresenta os principais requisitos funcionais do sistema.

Tabela 3 – Requisitos Funcionais.

Descrição
Analisar imagens para detectar parasitas utilizando modelos de aprendizado profundo.
Interface WEB para upload, visualização e gerenciamento de imagens microscópicas.
Sistema de autenticação com registro, login e recuperação de senha.
Gerenciamento de laboratórios colaborativos com controle de acesso por usuário.
Sistema de convites por email para participação em laboratórios.
Definição de funções e permissões hierárquicas dentro dos laboratórios.
Construção de dispositivo robótico para automação da captura microscópica.
Captura automática de imagens com varredura sistemática de lâminas.
API REST para integração com sistemas externos e aplicações terceiras.
Armazenamento de imagens, diagnósticos e metadados associados.

O primeiro requisito refere-se à capacidade do sistema de analisar imagens para detectar parasitas, permitindo a identificação automatizada da *Leishmania*. Esse processo é realizado por meio de algoritmos de segmentação de imagem e aprendizado de máquina, que possibilitam a identificação de padrões característicos da presença do protozoário.

A interface para upload e visualização de imagens permite que os usuários carreguem imagens de lâminas de microscopia no sistema, possibilitando sua posterior análise. Além disso, essa funcionalidade possibilita a visualização das imagens processadas, facilitando a interpretação dos resultados pelos profissionais de saúde.

A construção de um dispositivo para manipulação do microscópio é um componente essencial para garantir a automação do processo de captura de imagens. Esse dispositivo viabiliza o controle remoto do equipamento, reduzindo a necessidade de intervenção manual e aumentando a precisão da coleta de dados.

A captura automatizada de imagens por meio do dispositivo de captura otimiza o processo diagnóstico, permitindo a aquisição sequencial e padronizada de imagens microscópicas. Esse recurso reduz o tempo necessário para a análise e minimiza erros decorrentes da variabilidade manual na operação do microscópio.

Por fim, o armazenamento de imagens e dados de diagnóstico garante que todas as informações obtidas sejam registradas de maneira organizada e segura. Isso possibilita a rastreabilidade dos exames, a comparação de diferentes análises e o acompanhamento contínuo de casos clínicos, contribuindo para a tomada de decisões médicas fundamentadas.

4.2.2 Requisitos Não Funcionais

Os requisitos não funcionais definem critérios técnicos e de qualidade que influenciam o desempenho e a usabilidade do sistema. Esses requisitos garantem que a aplicação funcione de maneira eficiente, esteja acessível aos usuários e seja capaz de lidar com grandes volumes de dados. A Tabela 4 apresenta os requisitos não funcionais considerados no desenvolvimento do sistema.

Tabela 4 – Requisitos Não Funcionais.

Descrição
Acessibilidade via WEB responsiva em dispositivos desktop e móveis.
Processamento assíncrono de imagens para não bloquear interface do usuário.
Autenticação para segurança.
Compatibilidade com navegadores modernos.

A acessibilidade via WEB de qualquer dispositivo permite que o sistema seja utilizado em diferentes ambientes e por diferentes usuários, independentemente da plataforma utilizada. Essa abordagem proporciona maior flexibilidade para profissionais de saúde, que podem acessar os dados e os diagnósticos sem restrições de localização ou equipamento.

4.2.3 Regras de Negócio

As regras de negócio estabelecem as restrições e permissões dentro do sistema, garantindo que apenas usuários autorizados tenham acesso a determinadas funcionalidades. Essas regras são essenciais para garantir a segurança e a integridade dos dados armazenados. A Tabela 5 apresenta as principais regras de negócio adotadas.

O primeiro item estabelece a necessidade de autenticação para acessar os dados do sistema, garantindo que apenas usuários registrados possam visualizar e manipular as informações armazenadas. Essa medida visa assegurar a privacidade dos dados e evitar acessos não autorizados.

Tabela 5 – Regras de Negócio.

Descrição
Autenticação obrigatória para acessar todas as funcionalidades do sistema.
Apenas super usuários podem criar novos laboratórios.
Administradores de laboratório podem convidar e gerenciar participantes.
Acesso a lâminas e imagens restrito aos membros do laboratório proprietário.
Convites por email possuem token único e expiração de 7 dias.
Usuários podem participar de múltiplos laboratórios simultaneamente.
Processamento de imagens ocorre apenas para usuários autenticados.

A restrição de acesso a relatórios para usuários autorizados impede que informações sensíveis sejam visualizadas por indivíduos não credenciados. Essa regra é essencial para preservar a confidencialidade dos diagnósticos e proteger a integridade das análises realizadas pelo sistema.

Por fim, o compartilhamento de dados entre membros de uma mesma equipe possibilita a colaboração entre profissionais de saúde, permitindo que diagnósticos e imagens sejam analisados coletivamente. Essa funcionalidade melhora a tomada de decisões médicas e contribui para um diagnóstico mais preciso.

4.3 Diagrama de Caso de Uso

O Diagrama de Caso de Uso apresentado na Figura 6 representa a interação dos usuários com o sistema e suas funcionalidades. Ele modela as principais operações do sistema, destacando dois atores principais: Patologista e Administrador.

O patologista, tem como principal função interagir com as lâminas de microscopia digitalizadas, utilizando a plataforma para upload de imagens, captura automatizada e análise diagnóstica. O patologista pode configurar os parâmetros da captura, garantindo que as imagens sejam registradas de maneira padronizada. Já o Administrador é responsável pelo gerenciamento do sistema, incluindo a administração dos usuários e laboratórios associados. Este papel garante o controle de acesso às informações e a segurança dos dados.

As principais funcionalidades do sistema incluem:

1. Cadastro e gerenciamento de lâminas microscópicas: O patologista pode cadastrar novas lâminas e visualizar imagens já analisadas.
2. Upload de imagens: Permite o envio de imagens digitais das lâminas para análise.
3. Dispositivo de Captura Automatizada: Automatiza a captura das imagens microscópicas, minimizando a necessidade de intervenção manual.
4. Configuração de Tamanho da Lâmina: O usuário pode ajustar os parâmetros técnicos para a digitalização e análise das amostras.
5. Gerenciamento de usuários: O administrador pode criar, modificar e excluir contas de usuários, garantindo que apenas profissionais autorizados tenham acesso ao sistema.
6. Controle de laboratórios: O administrador também gerencia os laboratórios vinculados ao sistema, permitindo a organização dos exames e usuários por setor.

A estrutura apresentada no diagrama, Figura 6, reflete a organização funcional do sistema, detalhando as interações entre os usuários e suas respectivas permissões. A modelagem dos casos de uso garante a integração entre o dispositivo de captura e o processamento das imagens microscópicas, permitindo que os patologistas realizem o diagnóstico de maneira sistemática. O administrador desempenha um papel essencial no gerenciamento de usuários e laboratórios, assegurando o controle de acesso e a manutenção dos dados.

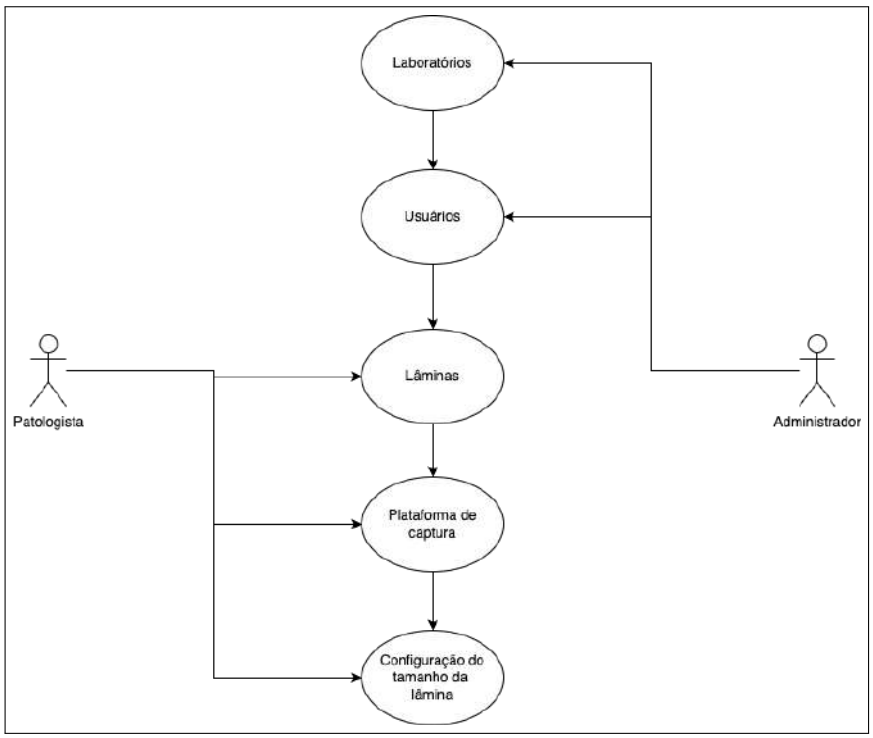


Figura 6 – Diagrama de Caso de Uso do sistema.

4.4 Aplicação WEB e Servidor

O sistema foi desenvolvido seguindo uma arquitetura de aplicação web moderna, separando o *backend* do *frontend* para maior flexibilidade e escalabilidade.

O *framework* Django (versão 4) foi utilizado para implementar o *backend* do sistema. Por ser escrito em Python, o Django facilitou a integração direta com as bibliotecas de aprendizado de máquina (TensorFlow, Ultralytics) empregadas no processamento das imagens, unificando o servidor de aplicação e os modelos de IA no mesmo ecossistema. A arquitetura nativa do *framework* foi utilizada para implementar o sistema de autenticação e o controle de permissões para os módulos *accounts* e *laboratory*. Para a comunicação com o *frontend*, foi desenvolvida uma API REST com o *Django REST Framework* (DRF). Esta biblioteca proveu as ferramentas para *serializers* (validação de dados), *viewsets* (*endpoints* da API) e *filters* (consultas parametrizadas), gerenciando a lógica de negócio e o processamento de lâminas.

O *frontend* foi desenvolvido como uma *Single-Page Application* (SPA) utilizando Vue.js 3[1] (YOU, 2024). A arquitetura reativa do *framework* foi importante para gerenciar a complexidade da captura automática, permitindo a mudança de elementos na tela sem necessitar recarregar a página, além de proporcionar um desenvolvimento mais rápido e organizado com sua estrutura de componentes.

[1] Vue.js é um *framework* JavaScript progressivo para a construção de interfaces de usuário. Sua reatividade e arquitetura baseada em componentes facilitam a criação de aplicações grandes e de página única (*Single-Page Applications*).

O gerenciamento de estado global da aplicação foi implementado com a biblioteca Pinia[2] (MOROTE; TEAM, 2024), enquanto o roteamento de páginas ficou a cargo do Vue Router[3]. A composição da interface e a estilização utilizaram a biblioteca de componentes PrimeVue[4] (PRIMETEK, 2024) e o *framework* Tailwind CSS[5] (WATHAN et al., 2024). O ambiente de desenvolvimento foi otimizado com o Vite[6] (YOU; TEAM, 2024) como *bundler*. O TypeScript foi adotado para adicionar tipagem estática ao JavaScript, visando a manutenibilidade do código e a redução de erros em tempo de desenvolvimento, complementado pelo ESLint para padronização.

A persistência dos dados foi garantida pelo sistema de gerenciamento de banco de dados PostgreSQL[7] (PostgreSQL Global Development Group, 2025), escolhido por sua adequação a aplicações que demandam alta integridade de dados.

O processamento assíncrono das imagens, uma tarefa computacionalmente intensiva, foi implementado com o Celery[8] (CELERY, 2025), permitindo que seja processado essas imagens em segundo plano. Esta arquitetura utiliza o RabbitMQ[9] (RABBITMQ, 2025) como *message broker*, que gerencia a fila e o agendamento das tarefas de análise de imagem.

O sistema de processamento integra modelos de aprendizado profundo, utilizando TensorFlow [10] (ABADI et al., 2015) para a classificação de imagens com a arquitetura InceptionV3, e a biblioteca Ultralytics YOLOv8[11] para a detecção de objetos. As operações de manipulação e processamento de imagens foram suportadas por bibliotecas consolidadas como OpenCV (BRADSKI, 2000), NumPy (HARRIS et al., 2020) e scikit-image (WALT et al., 2014). Para otimizar o uso de memória durante a execução dos modelos, o *worker* do Celery foi configurado com os parâmetros *pool=solo* e *prefetch-multiplier=1*[12].

A aplicação foi implantada na plataforma Microsoft Azure[13] (MICROSOFT, 2024), utilizando uma arquitetura distribuída em duas máquinas virtuais para otimização de recursos e custos. A infraestrutura foi dividida em um nó de aplicação, composto por uma máquina virtual Standard B1ms com 1 vCPU e 2 GiB de RAM, que hospeda os serviços Nginx, a aplicação web Django e o *worker* Celery (onde será feito o processamento das imagens). Esta configuração garante o isolamento adequado entre os serviços de interface e processamento. O segundo, um nó de dados, utiliza uma máquina virtual Standard B2ats v2 com 2 vCPUs e 1 GiB de RAM, dedicada aos serviços de infraestrutura RabbitMQ e PostgreSQL, permitindo uma otimização específica para operações de I/O e persistência.

---

[2] Pinia é a biblioteca de gerenciamento de estado recomendada para o Vue.js, oferecendo uma API simples, intuitiva e com forte integração com as ferramentas de desenvolvimento do Vue.

[3] Vue Router é a biblioteca de roteamento oficial para o Vue.js, permitindo a navegação entre diferentes visualizações da aplicação sem a necessidade de recarregar a página.

[4] PrimeVue é uma suíte de componentes de UI para Vue que oferece um conjunto rico de elementos pré-construídos, acelerando o desenvolvimento e garantindo consistência visual.

[5] Tailwind CSS é um *framework* CSS *utility-first* para a criação rápida de interfaces customizadas, integrado ao PrimeUI para garantir responsividade e um design coeso.

[6] Vite é uma ferramenta de *build* que oferece um servidor de desenvolvimento extremamente rápido e otimiza o empacotamento de recursos para produção.

[7] PostgreSQL é um sistema de gerenciamento de banco de dados relacional de código aberto, reconhecido por sua confiabilidade, robustez e capacidade de lidar com operações complexas.

[8] Celery é um sistema de filas de tarefas distribuído e assíncrono, essencial para executar operações de longa duração, como a análise de imagens, em segundo plano sem bloquear a interface do usuário.

[9] RabbitMQ é um *message broker* de código aberto que implementa o protocolo AMQP (Advanced Message Queuing Protocol), gerenciando a comunicação e a distribuição de tarefas entre a aplicação principal e os *workers* do Celery.

[10] TensorFlow é uma plataforma de código aberto para aprendizado de máquina, desenvolvida pelo Google, que oferece um ecossistema abrangente de ferramentas e bibliotecas para a construção e treinamento de modelos de redes neurais.

[11] YOLO (You Only Look Once) é uma família de modelos de detecção de objetos em tempo real. A versão 8, desenvolvida pela Ultralytics, é reconhecida por sua alta performance e precisão.

[12] A configuração *pool=solo* instrui o *worker* a executar tarefas sequencialmente em um único processo, medida crucial para evitar conflitos de alocação de memória da GPU. O parâmetro *prefetch-multiplier=1* garante que o *worker* reserve apenas uma tarefa por vez, uma estratégia para tarefas de maior duração que previne o acúmulo de tarefas na fila interna do *worker* em caso de falhas.

[13] Microsoft Azure é uma plataforma de computação em nuvem que oferece um vasto conjunto de serviços, incluindo máquinas virtuais, bancos de dados e ferramentas de orquestração, permitindo a implantação de aplicações escaláveis e resilientes.

Para garantir a modularidade e escalabilidade do sistema, foi utilizado o Docker (DOCKER, 2025), permitindo a criação de contêineres independentes para cada serviço essencial. A infraestrutura foi organizada com o Docker Compose em uma arquitetura que inclui um contêiner web para a aplicação Django, executada através do Gunicorn (GUNICORN, 2025) com configurações otimizadas para produção; um contêiner *worker* para o Celery, com limite de memória de 800MB; um contêiner para o banco de dados PostgreSQL com volumes persistentes; um contêiner para o *message broker* RabbitMQ, com *healthcheck* para monitoramento; e, por fim, um contêiner Nginx atuando como proxy reverso para servir conteúdo estático, realizar *load balancing* e gerenciar certificados SSL/TLS.

Os contêineres proporcionaram o isolamento de processos, facilitando a implantação, atualização e manutenção do sistema. O uso de *network_mode: host* nos contêineres evita sobrecarga na rede *bridge* do Docker, melhorando a comunicação entre serviços internos. A configuração de *restart: always* garante que os contêineres sejam reiniciados automaticamente em caso de falhas, aumentando a resiliência do sistema. A gestão de volumes Docker permite persistência de dados críticos (banco de dados, arquivos de mídia) e facilita operações de backup e recuperação.

A arquitetura modular permite realizar posteriormente uma escalabilidade horizontal através da adição de novos *workers* Celery conforme demanda de processamento, sem impactar os demais serviços. O monitoramento de recursos foi implementado através de limites de memória específicos para cada contêiner, prevenindo consumo excessivo de recursos e garantindo estabilidade operacional.

4.5 Detecção de Amastigotas

Para a detecção automatizada de amastigotas de *Leishmania*, foram implementados dois modelos de aprendizado profundo específicos para os contextos do diagnósticos da LVH e LVC. Visto que o foco principal deste trabalho reside no desenvolvimento e integração da plataforma de *software* e *hardware*, e não na criação de novas arquiteturas de *machine learning*, optou-se por integrar soluções de detecção já desenvolvidas e validadas pelo grupo de pesquisa. Desta forma, os algoritmos propostos em Goncalves et al. (2023) para LVH e em Borges et al. (2024) para LVC foram integrados ao sistema para formar uma abordagem de multi-modelos. Essa integração permite maior flexibilidade e adaptação a diferentes cenários diagnósticos, proporcionando uma solução automatizada e escalável para a detecção da LVH, LVC e de outras doenças.

4.5.1 Modelo para Leishmaniose Visceral Humana

Para a LVH, foi utilizada a arquitetura InceptionV3, conforme descrito em (GONCALVES et al., 2023). Esse modelo foi projetado para classificar amastigotas em amostras de medula óssea de pacientes humanos, utilizando uma abordagem de classificação binária para determinar a presença ou ausência do parasita. O treinamento do modelo utilizou um conjunto de 150 imagens capturadas através de câmera digital acoplada ao microscópio *Olympus Cba* com ampliação de 100x, com dimensões variando entre 768 $\times$ 949 e 3000 $\times$ 4000 pixels, das quais 78 foram classificadas como positivas para a presença de amastigotas.

A implementação seguiu uma abordagem de transferência de aprendizado utilizando pesos pré-treinados no conjunto de dados ImageNet. Inicialmente, todas as camadas convolucionais foram congeladas para preservar as características aprendidas, adicionando-se uma camada de *Global Average Pooling* que converte os mapas de características espaciais em um vetor unidimensional, seguida de uma camada densa com função de ativação sigmoid para classificação binária entre presença e ausência de amastigotas.

O processo de treinamento foi dividido em duas fases distintas. Na primeira etapa, apenas as camadas adicionadas foram treinadas por 20 épocas com taxa de aprendizado de 0,0001, utilizando o

otimizador Adam. Na segunda fase, foi aplicada a técnica de *fine-tuning*, descongelando todas as camadas do modelo pré-treinado e retreinando por 10 épocas adicionais com taxa de aprendizado reduzida para 0,00001. A função de perda *binary crossentropy* foi utilizada durante todo o processo, adequada para problemas de classificação binária. Para prevenir sobreajuste, foi aplicado *dropout* de 20% na camada totalmente conectada.

Para adequar as imagens aos requisitos de entrada do modelo InceptionV3, foi aplicado pré-processamento que incluiu redimensionamento para dimensões fixas de 299 × 299 pixels utilizando interpolação bilinear, mantendo a proporção das características originais das amastigotas. A técnica de aumento de dados (*data augmentation*) foi empregada para ampliar artificialmente a diversidade do conjunto de treinamento, incluindo transformações geométricas como rotações aleatórias no intervalo de 0° a 10° (sentido horário e anti-horário), inversões horizontais e verticais aleatórias, aplicação de *zoom* aleatório de até 10% para evitar perda de regiões importantes como as amastigotas, e ajustes de contraste com fator de 0,2 para simular variações na iluminação microscópica.

A validação do modelo foi conduzida através de validação cruzada k-fold com k=5, onde o conjunto de dados foi dividido aleatoriamente em 5 subconjuntos de tamanhos similares. Em cada iteração, 4 subconjuntos foram utilizados para treinamento e validação (70% treino, 10% validação) e 1 subconjunto para teste (20%), garantindo que todas as imagens fossem utilizadas pelo menos uma vez como conjunto de teste. As métricas finais foram calculadas como a média e desvio padrão das 5 iterações de classificação.

4.5.2 Modelo para Leishmaniose Visceral Canina

Para a LVC, foi utilizada a arquitetura YOLOv8, conforme descrito em (BORGES et al., 2024). Esta abordagem difere fundamentalmente da metodologia aplicada para LVH, pois permite simultaneamente a detecção, localização e quantificação das amastigotas em imagens microscópicas da medula óssea de cães. O algoritmo é capaz de identificar múltiplos parasitas em uma única imagem, fornecendo coordenadas precisas de cada detecção através de caixas delimitadoras (*bounding boxes*), o que reduz significativamente a necessidade de análises manuais exaustivas.

O treinamento utilizou um conjunto de dados especializado contendo 30 imagens microscópicas de medula óssea canina, nas quais foram anotados 2766 parasitas por especialistas do laboratório colaborador. Cada amastigota foi demarcada através de caixas delimitadoras retangulares com coordenadas precisas (x, y, largura, altura) e classificada como classe única amastigota.

O modelo foi configurado com dimensões de entrada de 1920 × 1080 pixels. O treinamento foi conduzido com transferência de aprendizado, com 317 épocas com tamanho de lote (*batch size*) igual a 2 e taxa de aprendizagem inicial de 0,01 com decaimento programado. O conjunto de dados foi dividido considerando tanto o número de imagens quanto a distribuição de parasitas por imagem, resultando na divisão: 80% para treinamento, 10% para validação e 10% para teste.

4.6 Considerações Finais

A metodologia detalhada neste capítulo representa uma abordagem integrada que combina o desenvolvimento de hardware, a engenharia de software e a aplicação de técnicas de aprendizado profundo para endereçar o desafio do diagnóstico da Leishmaniose Visceral. Cada recurso foi selecionado para construir uma solução escalável para atender vários clientes.

A construção de um dispositivo de captura automatizado e de baixo custo é fundamental, estabelecendo uma solução viável para padronizar e agilizar a aquisição de imagens microscópicas. A arquitetura do sistema web, baseada em tecnologias escaláveis como Django, Vue.js e Docker, foi projetada

para oferecer uma ferramenta de análise e captura, e também uma plataforma que poderá ser expandida para contemplar outras doenças e funcionalidades voltada a saúde.

5 Resultados e Discussão

Esta seção apresenta os resultados obtidos no desenvolvimento da aplicação WEB, do dispositivo de captura, do modelo de detecção de amastigotas utilizado e da avaliação de usabilidade do sistema. São abordadas as funcionalidades e tecnologias empregadas na construção da aplicação WEB, bem como os detalhes técnicos do dispositivo de captura. Além disso, discute-se o funcionamento da captura automatizada de imagens microscópicas e a metodologia utilizada na detecção das amastigotas. Por fim, são apresentados os dados da avaliação de usabilidade do sistema, considerando a percepção dos usuários e a eficiência da interface. As demais seções dos resultados incluem: Avaliação de Desempenho da Captura Automática (5.1), Construção da Aplicação WEB (5.2), Sistema de Gerenciamento de Laboratórios (5.3), Avaliação de Usabilidade do Sistema (5.4) e Detecção de Amastigotas (5.5)

5.1 Avaliação de Desempenho da Captura Automática

Para avaliar a eficiência do dispositivo de captura automática desenvolvido, foi conduzido um teste comparativo entre o método automatizado e a captura manual tradicional. O experimento foi realizado utilizando lâminas microscópicas preparadas com amostras de medula óssea.

O teste de captura automática foi conduzido com o dispositivo acoplado ao microscópio, configurado para capturar imagens em uma área padronizada da lâmina. O sistema foi programado para realizar varredura sistemática, capturando imagens com sobreposição mínima entre campos adjacentes para garantir cobertura completa da amostra. Durante o teste, foram capturadas 300 imagens de uma lâmina em um período de 35 minutos. Para comparação, foi realizado um teste de captura manual onde foi utilizado o mesmo microscópio para capturar imagens de lâminas similares. O teste manual resultou na captura de 200 imagens de uma lâmina em 60 minutos, representando o desempenho típico de um operador que faz esse tipo de coleta. A diferença da quantidade de imagens se dá pelo tamanho da área de interesse, além de que em uma captura manual podem ser saltadas regiões caso o operador determine já foi capturadas as mais relevantes para o diagnóstico.

A análise quantitativa dos resultados demonstrou que a captura automática atingiu uma taxa de 8,57 imagens por minuto, enquanto a captura manual apresentou taxa de 3,33 imagens por minuto. Estes dados indicam um ganho de eficiência na velocidade de captura, representando uma redução significativa no tempo necessário para documentar completamente uma lâmina microscópica.

5.2 Construção da Aplicação WEB

A aplicação possibilita o envio e gerenciamento de imagens microscópicas associadas a lâminas, sendo que uma única lâmina pode conter múltiplas imagens. A tela inicial do sistema, ilustrada na Figura 7, apresenta um *dashboard* com estatísticas dos últimos 7 dias, incluindo o número de lâminas analisadas e imagens processadas. O *layout* responsivo adapta-se automaticamente a diferentes dispositivos, garantindo acessibilidade tanto em *desktops* quanto em dispositivos móveis.

A interface principal oferece navegação através de um menu lateral que se adapta dinamicamente conforme as permissões do usuário logado. A Figura 8 demonstra a continuidade da página inicial, evidenciando o *design* responsivo que permite rolagem vertical para acomodar todo o conteúdo informativo.

O acesso às lâminas cadastradas é realizado por meio do menu lateral, onde são apresentadas

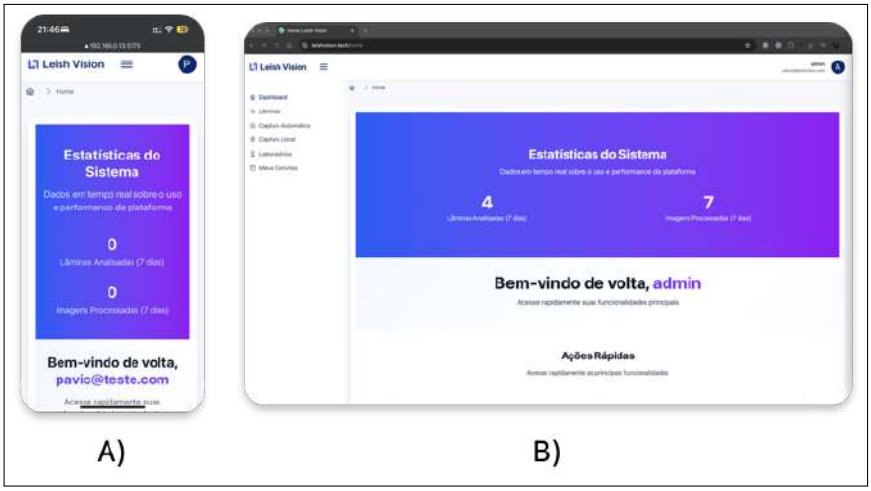


Figura 7 – (A) Tela inicial na visão mobile (B) Visão Desktop.

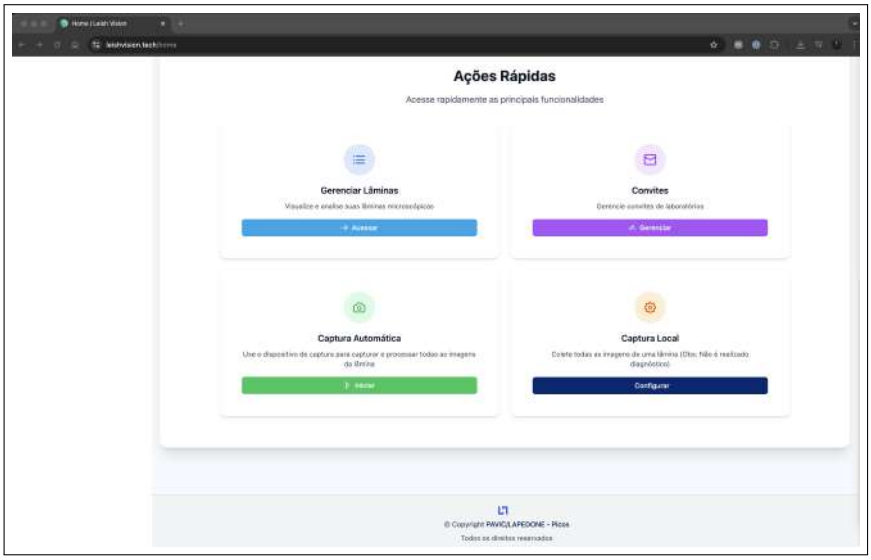


Figura 8 – Continuação da tela inicial do sistema, demonstrando o design responsivo com navegação por rolagem.

todas as lâminas disponíveis conforme as permissões do usuário. A Figura 9 ilustra a interface de listagem, que inclui filtros por tipo de processamento (humano ou canino), busca por nome da lâmina e paginação para otimizar a navegação em grandes volumes de dados. O resultado que indica se pelo menos uma imagem da lâmina apresentou resultado positivo no processamento automatizado.

Cada lâmina cadastrada deve estar vinculada a um laboratório específico, garantindo controle de acesso restrito aos membros autorizados. A adição de novas lâminas é realizada através de um formulário que requer a seleção do laboratório, definição de um nome para a lâmina e escolha do tipo de análise (humana ou canina), conforme demonstrado na Figura 10. Esta separação por tipo de análise permite que o sistema aplique o modelo de *machine learning* adequado para cada contexto diagnóstico.

A visualização detalhada das imagens associadas a uma lâmina é acessada através da seleção da respectiva lâmina na listagem. A Figura 11 apresenta a interface para lâminas do tipo humana, onde são exibidas todas as imagens processadas com suas respectivas classificações e percentuais de confiança. O sistema organiza as informações de forma clara, permitindo análise rápida dos resultados diagnósticos.

Para lâminas do tipo canina, a interface mantém o mesmo padrão de apresentação com a

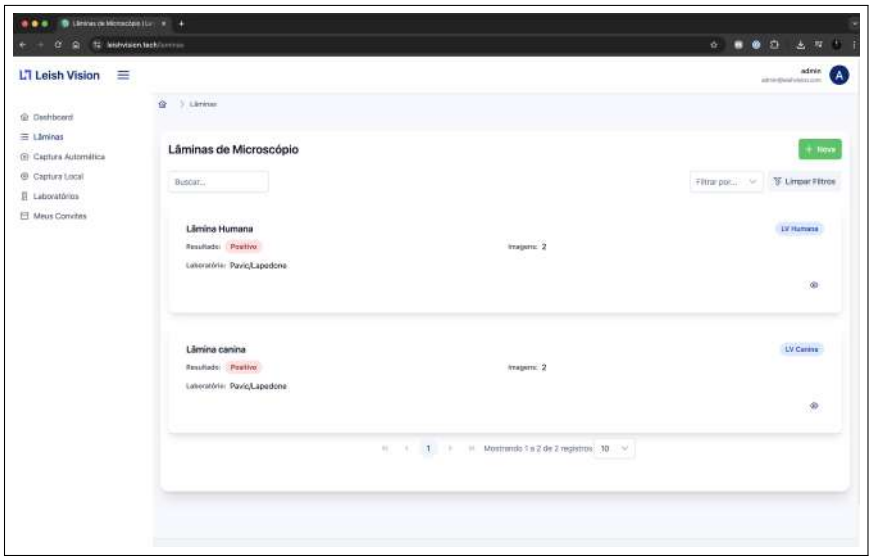


Figura 9 – Interface de listagem das lâminas cadastradas com filtros por tipo de processamento e classificação de resultados.

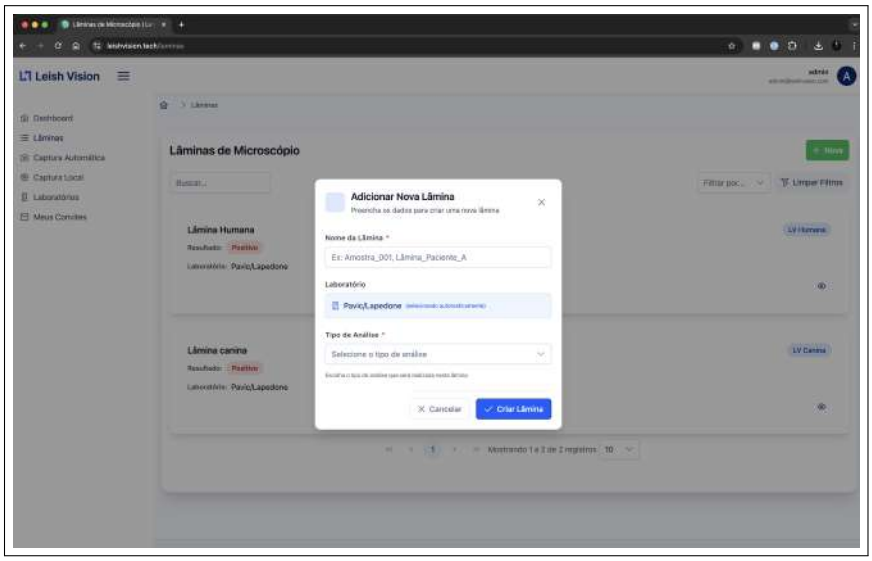


Figura 10 – Formulário para adição de nova lâmina com seleção de laboratório e tipo de análise.

diferenciação que é retornada a imagem de resultado destacando a presença da amastigota que determinou a classificação positiva, além de não mostrar a porcentagem de confiança, pois o modelo de classificação para este tipo de lâmina não utiliza essa métrica. A Figura 12 ilustra a interface de detalhamento para lâminas caninas, onde as imagens são apresentadas com informações relevantes para análise veterinária. Esta abordagem permite que profissionais da área identifiquem rapidamente os resultados e tomem decisões clínicas adequadas. A Figura 13 mostra o resultado gerado com as identificações das amastigotas.

A adição de imagens pode ocorrer através de duas modalidades: submissão manual pelo usuário ou captura automatizada utilizando o dispositivo desenvolvido. A Figura 14 apresenta o modal de seleção que permite ao usuário escolher entre essas opções. A integração entre as modalidades garante flexibilidade no fluxo de trabalho, atendendo diferentes cenários de uso.

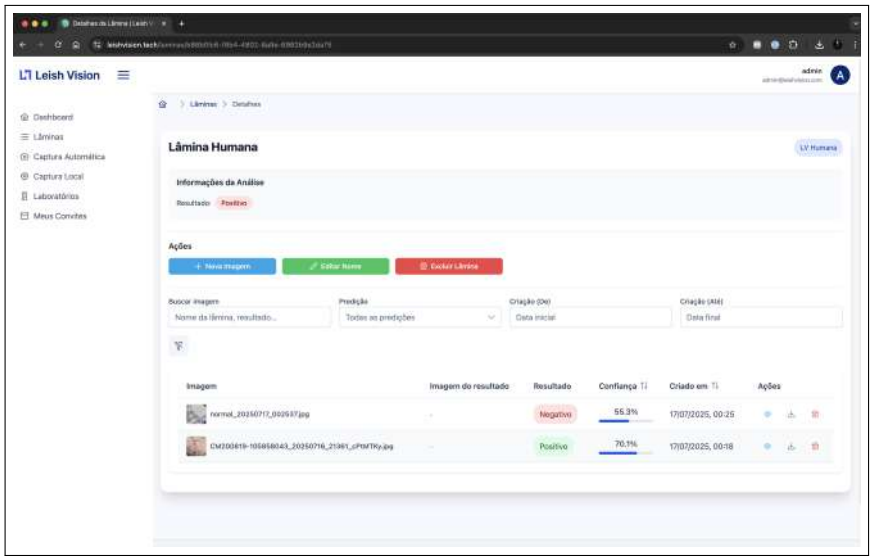


Figura 11 – Interface de detalhamento de lâmina do tipo humana, exibindo imagens processadas com classificações e percentuais de confiança.

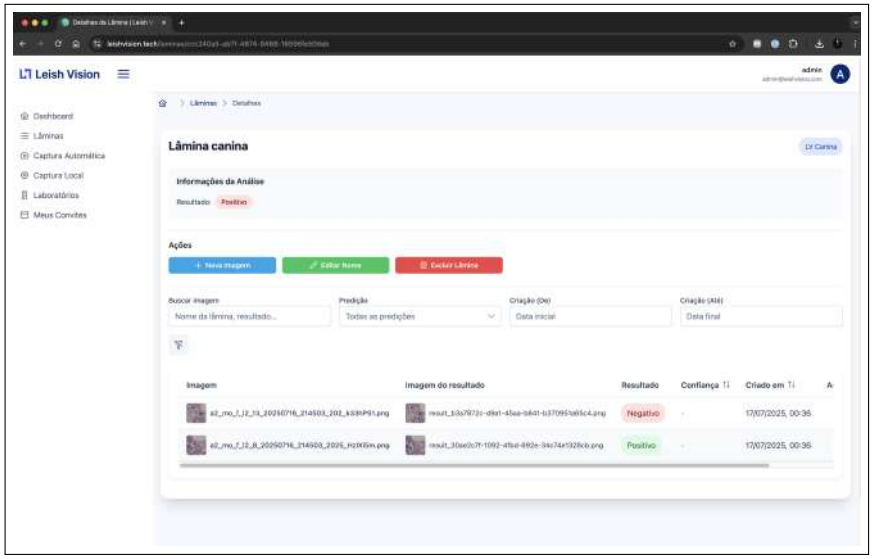


Figura 12 – Interface de detalhamento de lâmina do tipo canina.

5.3 Sistema de Gerenciamento de Laboratórios

O sistema implementa um modelo de gerenciamento de laboratórios que permite organização colaborativa para análise de amostras. Este módulo inclui funcionalidades para criação de laboratórios, gestão de participantes, controle de permissões e sistema de convites via e-mail.

O menu lateral da aplicação disponibiliza acesso direto às funcionalidades de laboratório e incluindo visualização de convites pendentes do usuário logado. A Figura 15 demonstra a interface principal de gestão, acessível tanto para superusuários do sistema quanto para usuários com função administrativa em laboratórios específicos.

Ao acessar os detalhes de um laboratório, os administradores podem visualizar todos os participantes ativos, suas respectivas funções e permissões. A Figura 16 apresenta esta funcionalidade, permitindo gerenciamento completo da equipe colaborativa do laboratório.

O sistema permite a criação de funções customizáveis para cada laboratório, oferecendo flexibili-

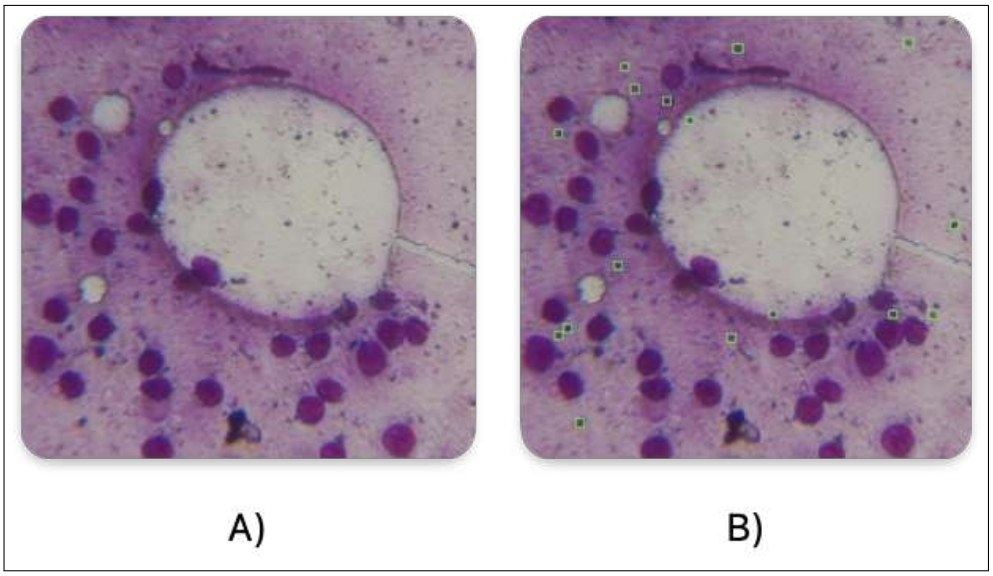


Figura 13 – Imagem microscópica original (A) com resultado da detecção das amastigotas em verde (B).

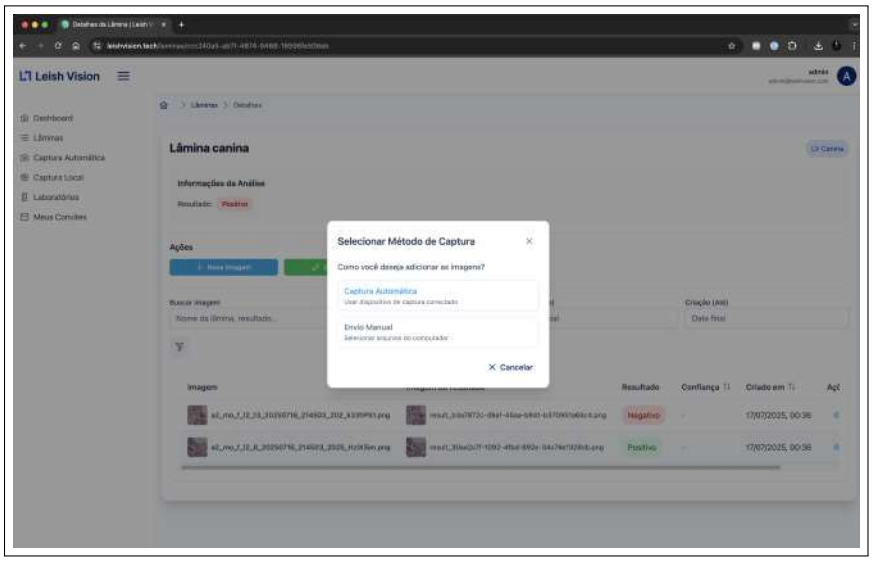


Figura 14 – Modal de seleção entre submissão manual e captura automatizada de imagens para a lâmina.

dade na definição de hierarquias e responsabilidades. A Figura 17 ilustra a interface de gerenciamento de funções, onde administradores podem criar, editar e definir permissões específicas para cada papel dentro do laboratório.

O sistema de convites automatizados facilita a inclusão de novos colaboradores nos laboratórios. A Figura 18 apresenta a interface de gestão de convites, onde administradores podem visualizar convites pendentes, criar novos convites via email e acompanhar o status de cada solicitação.

Os convites são enviados com *templates* personalizados e incluem *tokens* que expiram após 7 dias, após a expiração, o convite não pode mais ser aceito, mas o administrador pode reenviar o convite. O usuário convidado recebe um email com um link que o direciona para a página de cadastro, onde pode criar uma conta e aceitar o convite para participar do laboratório. A Figura 19 ilustra o email de convite recebido.

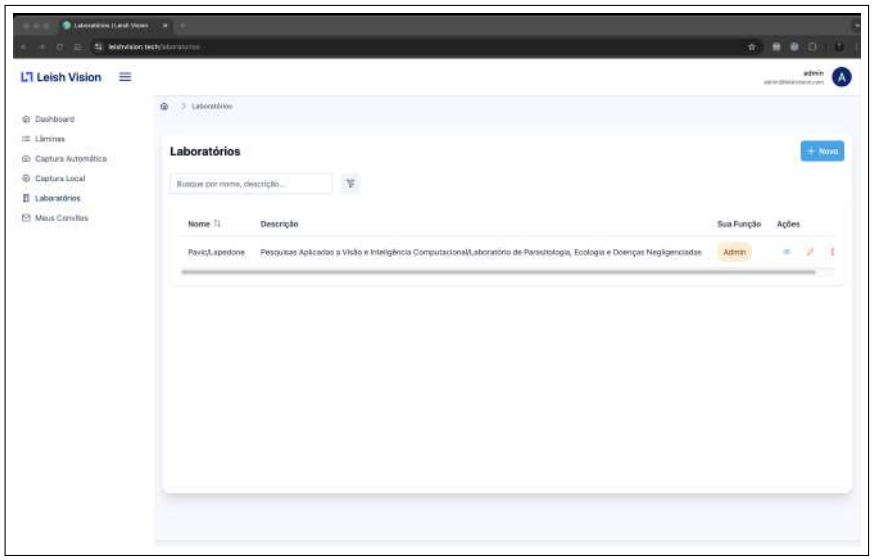


Figura 15 – Interface principal de gestão de laboratórios, disponível para superusuários e administradores de laboratório.

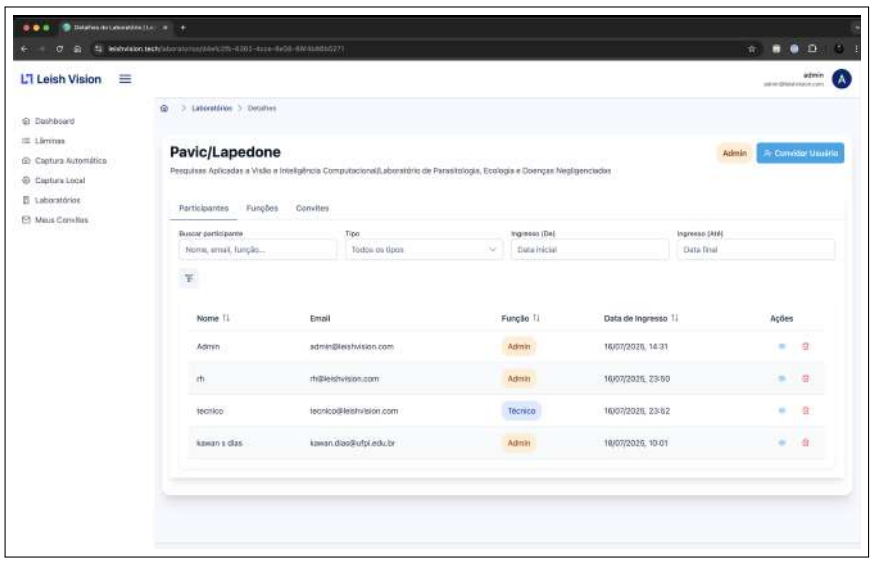


Figura 16 – Tela de detalhamento do laboratório apresentando lista de participantes e suas respectivas funções.

5.3.1 Configuração e Captura Automática

A funcionalidade de captura automática pode ser acessada através de duas rotas: diretamente pela lâmina (através do botão “Enviar Imagem” e seleção “Captura Automática”) ou através do atalho no menu lateral, que permite selecionar uma lâmina existente ou criar uma nova para o processo de captura.

Para realização de capturas automáticas, o dispositivo desenvolvido deve ser acoplado ao microscópio, conectado à fonte de alimentação e vinculado ao computador via cabo USB. O dispositivo físico é apresentado na Figura 5.

O processo de captura inicia-se com solicitações de permissão do navegador para acesso à câmera e dispositivos USB. As Figuras 20 e 21 demonstram estas etapas de autorização, necessárias para funcionamento das *APIs MediaDevices* e *Web Serial* respectivamente.

A interface inicial de captura automática, demonstrada na Figura 22, apresenta quatro opções principais: Configurar (definição de parâmetros), Capturar (inicialização do processo), Testar (validação

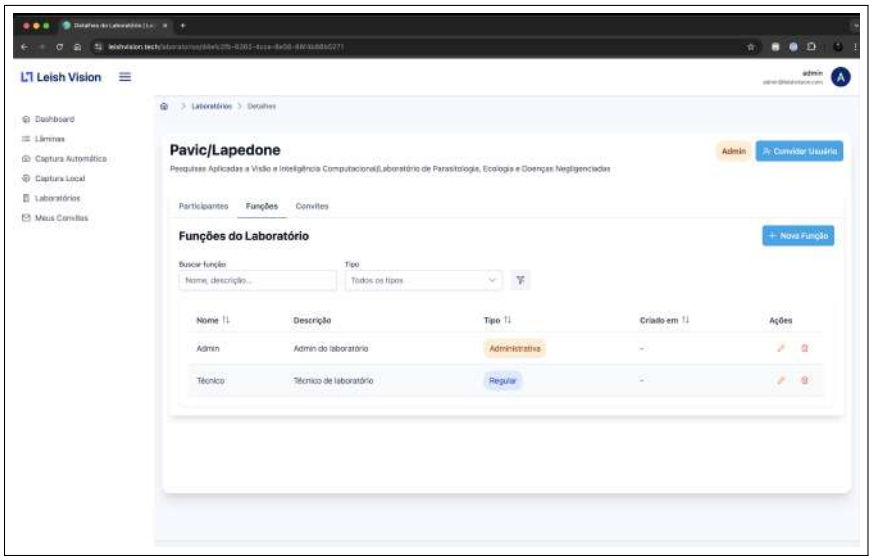


Figura 17 – Interface de gerenciamento de funções do laboratório, permitindo criação de papéis personalizados.

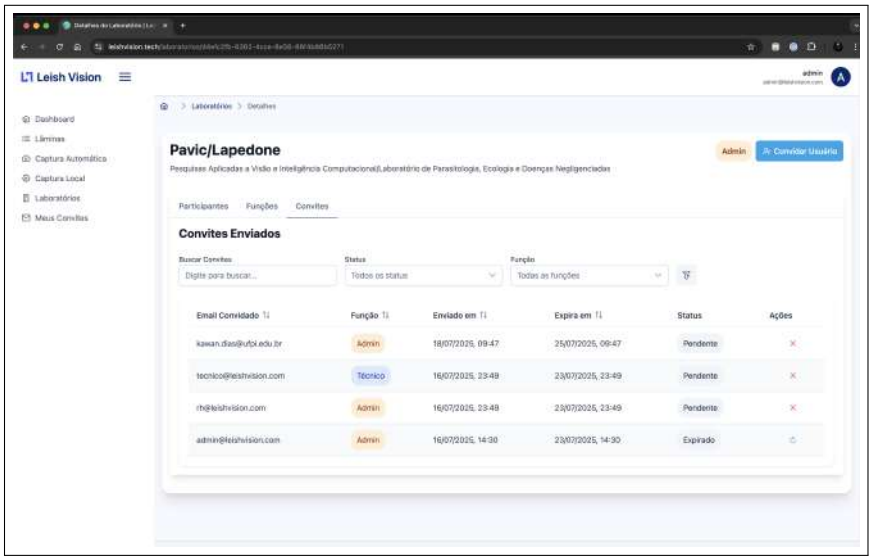


Figura 18 – Interface de gerenciamento de convites com visualização de solicitações pendentes e criação de novos convites.

das configurações previamente salvas) e Ajustar (permite movimentar a lâmina via botões de controle sem salvar as alterações). Esta organização permite fluxo de trabalho eficiente e reutilização de configurações entre sessões.

A configuração da captura envolve a definição das dimensões da lâmina na orientação horizontal, vertical e o tamanho das imagens a serem capturadas. A Figura 23 ilustram essas etapas. Após a realização dessa primeira configuração, o sistema permite que a última configuração utilizada seja armazenada e reaproveitada para futuras aquisições de imagens, garantindo maior eficiência no processo. Dessa forma, para novas lâminas, o usuário pode optar por reutilizar os parâmetros previamente definidos, reduzindo o tempo necessário para ajustes manuais e padronizando a captura das imagens.

Após a definição dos parâmetros, a opção Testar permite validar os ajustes antes da captura definitiva e verificar se a configuração previamente salva é adequada para uma nova lâmina. Na opção Capturar, as imagens são enviadas automaticamente para o servidor, onde o processamento ocorre em

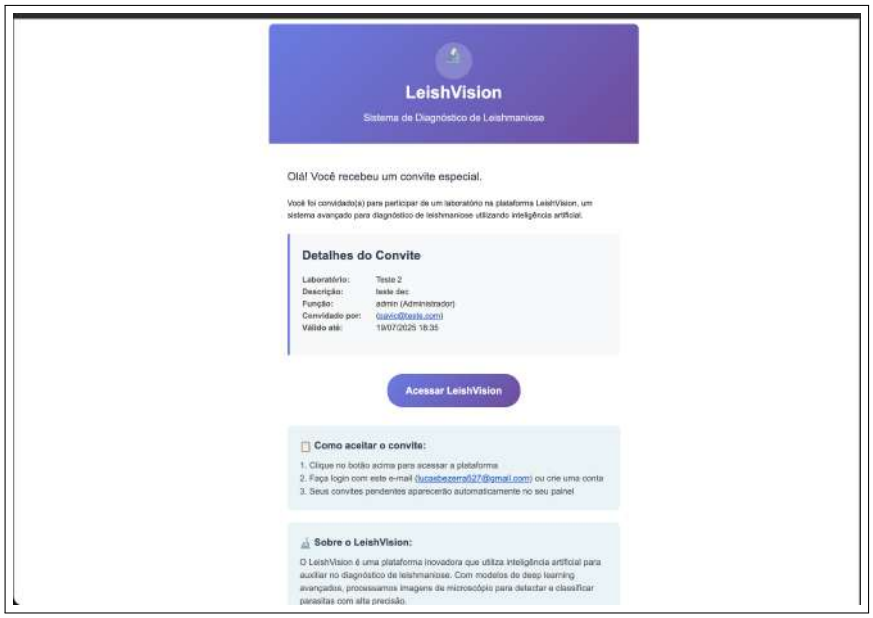


Figura 19 – Email de convite recebido pelo usuário convidado, contendo link para aceitação do convite e criação de conta.

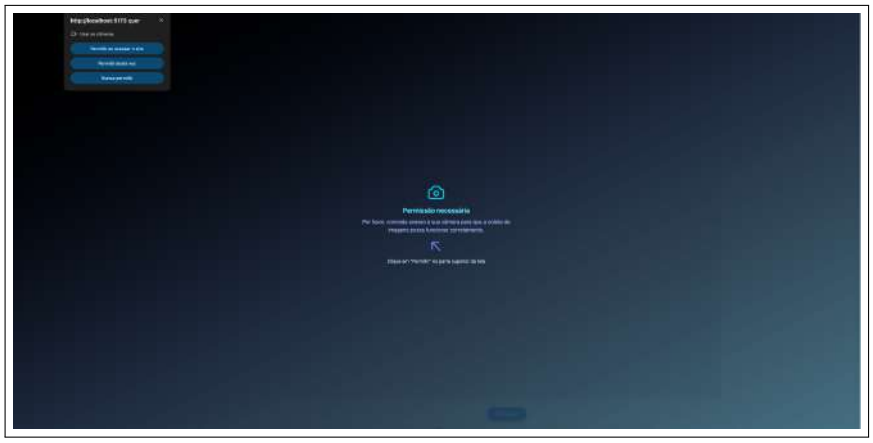


Figura 20 – Solicitação de permissão do navegador para acesso à câmera do dispositivo.

segundo plano.

Há também a presença de um menu suspenso, Figura 24, que permite ajustar a sensibilidade do foco, é exibido um aviso se a imagem estiver desfocada, além da sensibilidade a movimento para evitar de capturar imagens enquanto o dispositivo de captura ainda estiver movendo a lâmina. Além das opções de ajustar o tamanho da imagem exibida na tela e trocar a câmera se necessário e mostrar *logs* do sistema.

Foi desenvolvida também uma API para o recebimento de imagens durante o processo de captura automática. Essa API possibilita tanto a captura automatizada realizada pelo dispositivo de captura quanto a integração com sistemas de terceiros, permitindo maior flexibilidade e escalabilidade na utilização do sistema.

5.4 Avaliação de Usabilidade do Sistema

Para avaliar a usabilidade do sistema, foi aplicado o SUS a 13 participantes com diferentes perfis, incluindo estudantes de mestrado em Ciência da Computação, profissionais de Tecnologia da Informação, biólogos e veterinários.

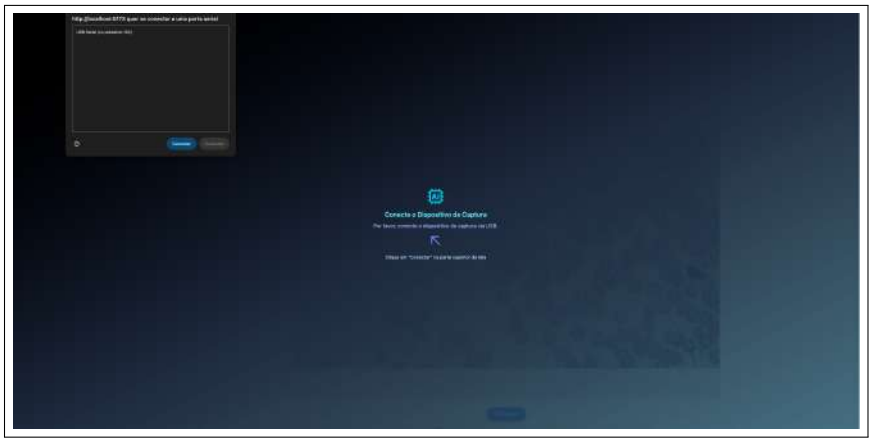


Figura 21 – Solicitação de permissão do navegador para acesso aos dispositivos USB conectados.

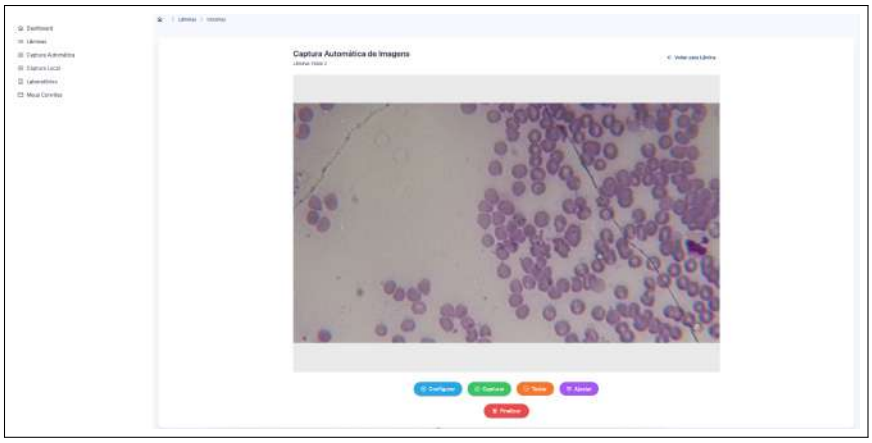


Figura 22 – Interface inicial da captura automática com opções de configuração, captura e teste.

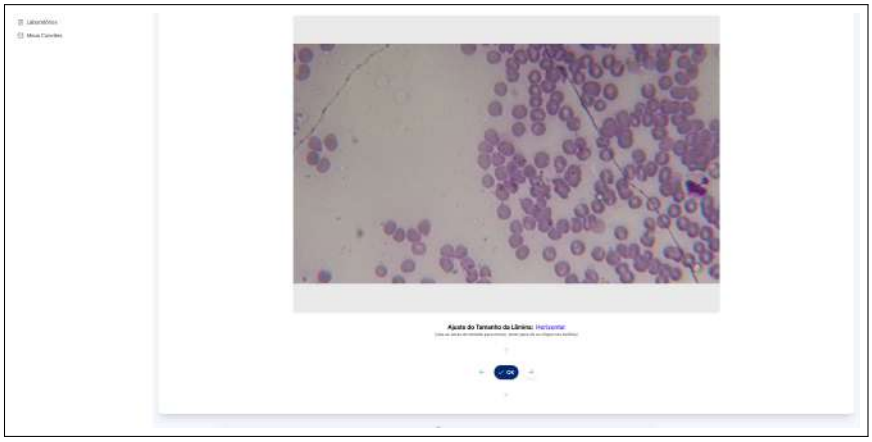


Figura 23 – Configuração das dimensões da lâmina nas orientações horizontal e vertical para definição da área de captura.

Cada participante respondeu a um questionário composto por dez afirmações, avaliadas em uma escala de 1 a 5, onde: (1) Discordo totalmente, (2) Discordo parcialmente, (3) Neutro, (4) Concordo parcialmente e (5) Concordo totalmente. A Tabela 6 apresenta os resultados obtidos a partir das respostas dos participantes.

Os resultados da escala SUS indicam uma pontuação média de 76,2, sugerindo que o sistema apresenta usabilidade acima da média. A pontuação variou entre 57,5 e 92,5, demonstrando diversidade nas percepções dos usuários.

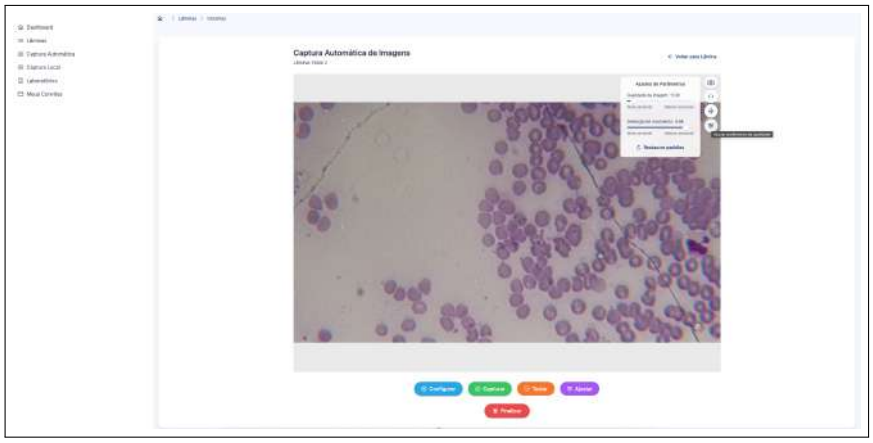


Figura 24 – Interface de configuração de parâmetros técnicos incluindo controles de foco, movimento e qualidade de imagem.

Participante	Q1	Q2	Q3	Q4	Q5	Q6	Q7	Q8	Q9	Q10	SUS Score
1	5	1	4	2	5	1	5	1	4	2	90,0
2	4	2	4	3	4	2	4	2	4	3	70,0
3	5	2	5	2	5	2	5	1	5	1	92,5
4	5	1	4	3	4	2	4	2	4	2	77,5
5	5	1	5	2	5	1	4	1	5	2	92,5
6	5	1	5	2	4	2	5	5	4	2	77,5
7	4	2	4	4	4	2	4	3	4	4	62,5
8	4	2	4	2	4	2	4	2	4	2	75,0
9	1	1	1	1	1	1	2	2	5	2	57,5
10	4	3	5	4	5	1	4	2	5	3	75,0
11	4	2	4	4	5	2	3	2	4	4	65,0
12	4	1	5	1	4	2	5	1	5	1	92,5
13	4	2	4	4	4	3	4	2	4	4	62,5

Tabela 6 – Resultados da avaliação de usabilidade utilizando a escala SUS.

A análise dos dados revelou que os participantes consideraram positivamente a integração das funções do sistema (Q5) e a facilidade de aprendizado (Q7). O *feedback* qualitativo complementar destacou o alto potencial da ferramenta para otimizar o trabalho de laboratório, sendo a funcionalidade de captura automática percebida como a de maior impacto por agilizar o processo e reduzir a subjetividade da análise manual. Por outro lado, as dificuldades quantitativas relacionadas à necessidade de suporte (Q4) e à curva de aprendizado inicial (Q10) foram corroboradas por observações qualitativas. Os usuários relataram pontos de atrito no fluxo de trabalho da interface, como a dificuldade em localizar a área de *upload* de imagens, a falta de redirecionamento automático após a criação de uma nova lâmina e a ausência de um indicador visual imediato sobre o status de processamento das imagens submetidas. Apesar destes pontos de melhoria identificados, a pontuação global obtida (76,2) supera a média de referência estabelecida na literatura (68,0), indicando uma boa aceitação geral da interface pelos usuários.

5.5 Detecção de Amastigotas

Na avaliação da LVH, o modelo InceptionV3, conforme reportado por Goncalves et al. (2023), alcançou 98,7% de precisão e F1-Score, com índice Kappa de 97,3%. Para a LVC, o modelo YOLOv8, segundo Borges et al. (2024), realizou classificação e detecção de amastigotas, apresentando 82,2% de precisão, 79,2% de recall, 85% de acurácia e mAP de 88,5%, com 226 dos 264 parasitas anotados detectados no conjunto de teste.

Esses resultados demonstram a eficácia dos modelos selecionados na automação do diagnóstico da LVH e LVC, reduzindo a necessidade de análises manuais, que podem ser exaustivas, possibilitando maior suporte para profissionais da área da saúde. Além disso, a integração dos modelos a aplicação WEB amplia o acesso à tecnologia, permitindo a análise de exames parasitológicos.

5.6 Considerações Finais

Os resultados detalhados neste capítulo demonstram a implementação funcional e a viabilidade da arquitetura de *software* e *hardware* proposta. A análise dos dados valida o atingimento dos objetivos específicos definidos para este trabalho.

Apesar da validação dos objetivos, é fundamental reconhecer as limitações metodológicas deste estudo. O foco do trabalho foi o desenvolvimento da ferramenta integrada (*hardware* e *software*), e não a proposição de novas arquiteturas de *machine learning*. Desta forma, os modelos InceptionV3 e YOLOv8 foram integrados a partir de trabalhos anteriores, podendo ser aprimorados com mais dados para treinamentos.

Além disso, identificaram-se limitações operacionais no dispositivo de captura: o processo de varredura, embora automatizado, ainda requer intervenção manual do operador para a configuração inicial da área de captura na lâmina. O sistema também não implementa um controle de foco automatizado, dependendo do ajuste manual prévio no microscópio para garantir a nitidez da imagem.

Adicionalmente, a avaliação de usabilidade (Seção 5.4), embora tenha apresentado uma pontuação média positiva, revelou limitações no fluxo de trabalho da interface. O *feedback* qualitativo dos participantes identificou pontos de atrito, tais como a falta de redirecionamento automático para a tela de *upload* após a criação de uma nova lâmina, a baixa intuitividade da área de clique para submissão de imagens e a ausência de uma mensagem de confirmação ou indicador visual imediato de que as imagens estavam sendo processadas após o *upload*.

Os resultados obtidos confirmam a viabilidade do sistema proposto como uma ferramenta de apoio diagnóstico. A avaliação positiva de usabilidade e o desempenho superior da captura automática em relação ao método manual validam a arquitetura desenvolvida.

6 Conclusões e Trabalhos Futuros

6.1 Conclusões

O diagnóstico parasitológico da Leishmaniose Visceral (LV), embora seja o método padrão-ouro, é um processo manual, demorado e suscetível à subjetividade do analista. Este trabalho respondeu a esse desafio através do desenvolvimento e validação de uma solução completa e integrada, composta por um dispositivo de *hardware* para captura automática e uma plataforma WEB de *software* para gerenciamento e análise.

A principal contribuição deste trabalho para os laboratórios de patologia é a demonstração de uma arquitetura viável, de baixo custo e eficiente para a otimização do diagnóstico da LV e outras doenças. O dispositivo robótico de captura, orçado em R$ 305,00, provou ser economicamente acessível e mais eficiente que o método de captura manual, aumentando a velocidade de varredura das lâminas. Paralelamente, a plataforma WEB colaborativa estabeleceu um ambiente organizado para a análise de amostras, unificando o gerenciamento de laboratórios, o controle do *hardware* e a aplicação de múltiplos modelos de *machine learning*.

Desta forma, os objetivos específicos do trabalho foram alcançados, resultando em um sistema funcional, integrado e com alta aceitação de usabilidade, validada pela aplicação do método SUS.

Contudo, há algumas limitações do estudo, o foco do trabalho foi a engenharia e a integração do sistema, e não a proposição dos modelos de *machine learning*. Embora os modelos InceptionV3 e YOLOv8 integrados possuam acurácia validada em seus trabalhos de origem, a generalização destes modelos para colorações diferentes e microscópios diferentes não foi avaliada neste trabalho.

Outro ponto a considerar são as limitações operacionais do protótipo de *hardware*, ainda possui limitações operacionais, como a necessidade de intervenção manual do operador para a configuração da área de varredura e, principalmente, a ausência de um controle de foco automatizado. A avaliação de usabilidade, embora positiva, também identificou pontos de atrito no *software*, como o fluxo de *upload* de imagens, que necessitam de refinamento.

Portanto, o sistema proposto cumpre sua finalidade de ser uma ferramenta de apoio diagnóstico viável e de baixo custo. As limitações identificadas não invalidam as contribuições centrais do trabalho, mas fornecem um direcionamento para trabalhos futuros.

6.2 Trabalhos Futuros

Com base nas limitações identificadas, os trabalhos futuros focarão no aprimoramento do hardware, do software e dos modelos de análise. Primeiramente, será abordada a limitação do dispositivo de captura, que ainda requer intervenção manual para definir as regiões de início e fim da lâmina, objetiva-se o desenvolvimento de um processo totalmente automatizado que elimine essa necessidade. Paralelamente, será desenvolvido um controle automatizado do foco do microscópio, permitindo maior precisão na aquisição das imagens.

No âmbito do software, o fluxo de trabalho da interface será refinado com base no *feedback* qualitativo da avaliação de usabilidade. As melhorias planejadas incluem o redirecionamento automático do usuário para a tela de upload após a criação de uma nova lâmina, a otimização da intuitividade da área de submissão de imagens e a implementação de indicadores visuais imediatos para o status de

processamento, informando ao usuário que a análise foi iniciada .

Por fim, está prevista a ampliação dos modelos de análise para incluir a detecção de macrófagos e a contagem de células infectadas, possibilitando uma avaliação mais detalhada da infecção. Também serão desenvolvidos novos módulos no sistema, como um módulo de pacientes, para associar formalmente cada lâmina a um diagnóstico de um animal ou humano.

Referências

ABADI, M. et al. *TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems*. 2015. Software available from tensorflow.org. Disponível em: <https://www.tensorflow.org/>. Citado na página 19.

AKHOUNDI, M. et al. A historical overview of the classification, evolution, and dispersion of leishmania parasites and sandflies. *PLoS neglected tropical diseases*, Public Library of Science San Francisco, CA USA, v. 10, n. 3, p. e0004349, 2016. Citado na página 1.

ARDUINO. 2024. <https://www.arduino.cc/>. Acessado em: 21 de Novembro de 2024. Citado na página 7.

BACETTI, G. F. et al. Avaliação do conhecimento da população residente no município de pacaraima/rr sobre leishmaniose/assessment of knowledge of the population living in the municipality of pacaraima/rr on leishmaniasis. *Brazilian Journal of Health Review*, v. 4, n. 2, p. 3979–3988, 2021. Citado na página 5.

BARROS, M. *Guia atualizado de como utilizar a escala SUS (System Usability Scale) no seu produto*. 2022. <https://brasil.uxdesign.cc/guia-atualizado-de-como-utilizar-a-escala-sus-system-usability-scale-no-seu-produto-ab773f29c522>. Acessado em: 12 de Janeiro de 2025. Citado na página 8.

BISHOP, C. M. *Pattern Recognition and Machine Learning*. [S.l.]: Springer, 2006. Citado na página 9.

BORGES, A. L. et al. *Detecção de Parasitas de Leishmaniose Visceral Canina Usando YOLOv8*. 2024. Apresentado no Simpósio Norte e Nordeste de Bioinformática. Banner SB_B_02. Data: 06/11/2024, 17:30-18:30. ID do trabalho: 012. Área: Softwares, bancos de dados e inteligência artificial. Citado 4 vezes nas páginas 2, 20, 21 e 32.

BRADSKI, G. *The OpenCV Library*. 2000. Citado na página 19.

BROOKE, J. System usability scale (sus). *Usability Net.*, 1986. Citado na página 8.

CASTRO, R. *Aumento de casos de leishmaniose em cães acende alerta para doença em humanos*. 2023. Disponível em: <https://portal.fiocruz.br/noticia/aumento-de-casos-de-leishmaniose-em-caes-acende-alerta-para-doenca-em-humanos>. Agência Fiocruz de Notícias. Acesso em 18 de Fevereiro de 2025. Citado na página 1.

CELERY. *Distributed Task Queue*. 2025. Disponível em <https://docs.celeryq.dev/en/stable/>. Acesso em 28 de janeiro de 2025. Citado na página 19.

DJANGO. *Security in Django*. 2025. Disponível em <https://docs.djangoproject.com/en/4.2/topics/security/>. Acesso em 28 de janeiro de 2025. Citado 2 vezes nas páginas 7 e 8.

DOCKER. *Docker - Automate and simplify software deployment*. 2025. Disponível em <https://www.docker.com/>. Acesso em 28 de janeiro de 2025. Citado na página 20.

FREUND, Y.; SCHAPIRE, R. E. A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of computer and system sciences*, Elsevier, v. 55, n. 1, p. 119–139, 1997. Citado na página 11.

GONCALVES, C. et al. Automatic detection of visceral leishmaniasis in humans using deep learning. *Signal, Image and Video Processing*, Springer, v. 17, n. 7, p. 3595–3601, 2023. Citado 5 vezes nas páginas 2, 11, 12, 20 e 32.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. [S.l.]: MIT Press, 2016. Citado na página 9.

GUNICORN. *Python WSGI HTTP Server for UNIX*. 2025. Disponível em <https://gunicorn.org/>. Acesso em 28 de janeiro de 2025. Citado na página 20.

HARRIS, C. R. et al. Array programming with NumPy. *Nature*, v. 585, p. 357–362, 2020. Citado na página 19.

HOTEZ, P. J. et al. The global burden of disease study 2010: interpretation and implications for the neglected tropical diseases. *PLoS neglected tropical diseases*, Public Library of Science San Francisco, USA, v. 8, n. 7, p. e2865, 2014. Citado na página 1.

HUSSAIN, M. et al. A survey on transfer learning. *Journal of Physics: Conference Series*, v. 1192, n. 1, p. 012005, 2019. Citado na página 9.

JOCHER, G.; CHAURASIA, A.; QIU, J. *YOLO by Ultralytics*. 2023. <https://github.com/ultralytics/ultralytics>. Acessado em: 04 de agosto de 2024. Citado na página 10.

KOUTINAS, A. F.; KOUTINAS, C. K. Pathologic mechanisms underlying the clinical findings in canine leishmaniosis due to leishmania infantum/chagasi. *Veterinary Pathology*, v. 51, n. 2, p. 527–538, 2014. Citado na página 1.

LARSSON, J.; HEDBERG, R. *Development of machine learning models for object identification of parasite eggs using microscopy*. 2020. Publicação do repositório DiVA Portal. Disponível em: diva-portal.org. Citado na página 11.

LEAO, S. D. S. et al. Intracellular leishmania amazonensis amastigotes internalize and degrade mhc class ii molecules of their host cells. *Journal of Cell Science*, The Company of Biologists Ltd, v. 108, n. 10, p. 3219–3231, 1995. Citado na página 6.

LEISHMANIOSE. 2023. Disponível em: <https://www.who.int/news-room/fact-sheets/detail/leishmaniasis>. Organização Mundial da Saúde. Acesso em 18 de Fevereiro de 2025. Citado na página 1.

MATURANA, C. R. et al. Advances and challenges in automated malaria diagnosis using digital microscopy imaging with artificial intelligence tools: A review. *Frontiers in microbiology*, Frontiers Media SA, v. 13, p. 1006659, 2022. Citado 2 vezes nas páginas 11 e 12.

MEDEIROS, A. I. M.; NEGREIROS, M. E. M. V. de. *RESERVATÓRIOS NÃO CONVENCIONAIS NA TRANSMISSÃO DAS LEISHMANIOSES NO BRASIL-REVISÃO DE LITERATURA*. 2022. Trabalho de Conclusão de Curso - Centro Universitário Doutor Leão Sampaio (Unileão). Disponível em: <sis.unileao.edu.br>. Citado na página 5.

MICROSOFT. *Microsoft Azure*. 2024. <https://azure.microsoft.com>. Acessado em: 04 de agosto de 2024. Citado na página 19.

MONTIRONI, M. A.; QIAN, B.; CHENG, H. H. Development and application of the charduino toolkit for teaching how to program arduino boards through the c/c++ interpreter ch. *Computer Applications in Engineering Education*, Wiley Online Library, v. 25, n. 6, p. 1053–1065, 2017. Citado na página 7.

MOREIRA, M. P. C. et al. Contribuições do arduino no ensino de física: uma revisão sistemática de publicações na área do ensino. *Caderno Brasileiro de Ensino de Física*, Universidade Federal de Santa Catarina (UFSC), v. 35, n. 3, p. 721–745, 2018. Citado na página 7.

MOROTE, E. S. M.; TEAM, T. V. *Pinia - The intuitive store for Vue.js*. 2024. <https://pinia.vuejs.org>. Acessado em: 04 de agosto de 2024. Citado na página 19.

NEVES, J. C. et al. Detection and separation of overlapping cells based on contour concavity for leishmania images. *Cytometry Part A*, Wiley Online Library, v. 85, n. 6, p. 491–500, 2014. Citado na página 2.

OLIVEIRA, A. Dantas de et al. Development of a low-cost robotized 3d-prototype for automated optical microscopy diagnosis: An open-source system. *Plos One*, Public Library of Science San Francisco, CA USA, v. 19, n. 6, p. e0304085, 2024. Citado 2 vezes nas páginas 11 e 12.

Organização Mundial da Saúde. *Leishmaniose*. 2023. Acesso em: 18 fev. 2025. Disponível em: <https://www.who.int/news-room/fact-sheets/detail/leishmaniasis>. Citado na página 1.

POSTGRESQL. *PostgreSQL: The World's Most Advanced Open Source Relational Database*. 2025. <https://www.postgresql.org/>. Acessado em: 12 de Janeiro de 2025. Citado na página 8.

PostgreSQL Global Development Group. *PostgreSQL: The World's Most Advanced Open Source Relational Database*. 2025. <https://www.postgresql.org>. Acessado em: 12 de Janeiro de 2025. Citado na página 19.

PRIMETEK. *PrimeVue - The Most Complete Vue UI Component Library*. 2024. <https://primevue.org>. Acessado em: 04 de agosto de 2024. Citado na página 19.

PUROHIT, N. A comparative study on open source database management system. *International Journal for Research in Applied Science and Engineering Technology*, v. 6, 04 2018. Citado na página 8.

RABBITMQ. *RabbitMQ Messaging Queue*. 2025. Disponível em <https://www.rabbitmq.com/>. Acesso em 28 de janeiro de 2025. Citado na página 19.

RIOS, L. C. et al. Leishmaniose visceral: Histórico, agente etiológico, ciclo biológico, vetor, diagnóstico e tratamento. *Tópicos nas ciências da saúde Volume X*, 2022. Citado na página 5.

SANTOS, H. C. d. N. et al. Produção e avaliação da atividade leishmanicida de extratos de fungos isolados da antártica e prospecção tecnológica de metabólitos fúngicos. Universidade Federal de Alagoas, 2023. Citado na página 1.

SAÚDE, M. da. *MINISTÉRIO DA SAÚDE - Leishmaniose Visceral*. 2024. Disponível em: <https://leishmanioses.aids.gov.br/app/dashboards?auth_provider_hint=anonymous1#/view/041e37d7-6f08-463e-8dd0-e43c5c2b34c4?embed=true&_g=()&show-top-menu=false>. Dashboards. Acesso em 18 de Fevereiro de 2025. Citado na página 1.

SHORTEN, C.; KHOSHGOFTAAR, T. M. A survey on image data augmentation for deep learning. *Journal of Big Data*, Springer, v. 6, n. 1, p. 1–48, 2019. Citado na página 10.

SILVA, J. M. et al. Bone marrow parasite burden among patients with new world kala-azar is associated with disease severity. *The American journal of tropical medicine and hygiene*, The American Society of Tropical Medicine and Hygiene, v. 90, n. 4, p. 621, 2014. Citado na página 2.

SILVA, L. A. et al. Antileishmania immunological tests for asymptomatic subjects living in a visceral leishmaniasis-endemic area in brazil. *The American journal of tropical medicine and hygiene*, The American Society of Tropical Medicine and Hygiene, v. 84, n. 2, p. 261, 2011. Citado na página 2.

SOUZA, E. K. B. d. Monografia, *Diagnóstico molecular da leishmaniose visceral humana por L. infantum: uma revisão atual da literatura*. 2019. Disponível em: <monografias.ufop.br>. Citado na página 6.

SOUZA, L. D. d. *Efeito do fator de crescimento insulina-símile-I em promastigota e amastigota intracelular de Leishmania (Viannia) braziliensis de pacientes com diferentes formas clínicas de leishmaniose tegumentar americana*. Tese (Doutorado) — Universidade de São Paulo, 2012. Citado na página 6.

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 10.

TEIXEIRA, F. *O que é o SUS (System Usability Scale) e como usá-lo em seu site*. 2015. <https://brasil.uxdesign.cc/o-que-%C3%A9-o-sus-system-usability-scale-e-como-us%C3%A1-lo-em-seu-site-6d63224481c8>. Acessado em: 12 de Janeiro de 2025. Citado na página 8.

UAMBA, A. P. Monografia (Engenharia de Computação), *Solução para queries complexas em bigdata utilizando mapreduce com banco de dados mongodb: um estudo de caso com dados do caged*. Redenção-CE: [s.n.], 2024. Disponível em: <https://repositorio.unilab.edu.br/jspui/handle/123456789/5749>. Citado na página 8.

VAMSI, K. M. et al. Visualization of real world enterprise data using python django framework. In: IOP PUBLISHING. *IOP Conference Series: Materials Science and Engineering*. [S.l.], 2021. v. 1042, n. 1, p. 012019. Citado na página 8.

VIOLA, P.; JONES, M. Rapid object detection using a boosted cascade of simple features. In: IEEE. *Proceedings of the 2001 IEEE computer society conference on computer vision and pattern recognition. CVPR 2001*. [S.l.], 2001. v. 1, p. I–I. Citado na página 11.

WALT, S. van der et al. scikit-image: Image processing in Python. *PeerJ*, v. 2, p. e453, 2014. Citado na página 19.

WAMAI, R. G. et al. Visceral leishmaniasis: a global overview. *Journal of Global Health Science*, v. 2, n. 1, 2020. Citado na página 1.

WARD, P. et al. Affordable artificial intelligence-based digital pathology for neglected tropical diseases: A proof-of-concept for the detection of soil-transmitted helminths and schistosoma mansoni eggs in kato-katz stool thick smears. *PLoS neglected tropical diseases*, Public Library of Science San Francisco, CA USA, v. 16, n. 6, p. e0010500, 2022. Citado 2 vezes nas páginas 11 e 12.

WATHAN, A. et al. *Tailwind CSS - A utility-first CSS framework*. 2024. <https://tailwindcss.com>. Acessado em: 04 de agosto de 2024. Citado na página 19.

YOU, E. *Vue.js*. 2024. <https://vuejs.org>. Acessado em: 04 de agosto de 2024. Citado na página 18.

YOU, E.; TEAM, T. V. *Vite - Next Generation Frontend Tooling*. 2024. <https://vitejs.dev>. Acessado em: 04 de agosto de 2024. Citado na página 19.

ZARE, M. et al. A machine learning-based system for detecting leishmaniasis in microscopic images. *BMC infectious diseases*, Springer, v. 22, n. 1, p. 48, 2022. Citado 2 vezes nas páginas 11 e 12.