

# Detecção Automática de Leishmaniose Visceral Canina Utilizando Deep Learning

Viviane Barbosa Leal  
Dias  
Sistemas de Informação,  
Universidade Federal do  
Piauí, Picos, Brasil  
vivianebarbosa@ufpi.edu.br

Armando Luz Borges  
Sistemas de Informação,  
Universidade Federal do  
Piauí, Picos, Brasil  
armandoluzborges@ufpi.edu.br

Clésio de Araújo  
Gonçalves  
Ciência da Computação,  
Universidade Federal do  
Piauí, Picos, Brasil  
Departamento de Informática,  
Instituto Federal do Sertão  
Pernambucano, Ouricuri,  
Brasil  
clesio.goncalves@ufpi.edu.br

Ana Carolina Landim  
Pacheco  
Ciências Biológicas,  
Universidade Federal do  
Piauí, Picos, Brasil  
carolandim@ufpi.edu.br

Dr. Daniel de Araújo  
Viana  
Universidade Estadual do  
Ceará, Tauá, Brasil  
Conselho Regional de  
Medicina Veterinária e  
Zootecnia do Ceará  
daniel.viana@uece.br

Romuere Rodrigues  
Veloso e Silva  
Sistemas de Informação,  
Universidade Federal do  
Piauí, Picos, Brasil  
Ciência da Computação,  
Universidade Federal do  
Piauí, Picos, Brasil  
romuere@ufpi.edu.br

## ABSTRACT

Leishmaniasis is a serious disease transmitted by infected mosquitoes, which affects both humans and animals and can result in fatality when adequate treatment is not received. It is important to receive an accurate diagnosis during the early stages of the disease. Although Computer Vision techniques can contribute to diagnosis, they are generally costly and time-consuming due to high computational requirements. This study aims to train low computational cost Convolutional Neural Networks to assist in diagnosing the disease. Our results were compared with four previous studies, and our method showed significant and promising results. This highlights that low-cost convolutional neural networks can be an effective approach for automated pathology diagnosis.

## ABSTRACT

A Leishmaniose é uma doença grave transmitida por mosquitos infectados, que afeta tanto humanos quanto animais, e pode resultar em fatalidade quando não recebe o tratamento adequado. É importante receber o diagnóstico preciso durante as fases iniciais da doença. Embora as técnicas de Visão Computacional possam contribuir para o diagnóstico,

elas geralmente são custosas e demoradas devido aos altos requisitos computacionais. Este estudo visa treinar Redes Neurais Convolucionais de baixo custo computacional para auxiliar no diagnóstico da doença. Nossos resultados foram comparados com quatro estudos anteriores, e nosso método demonstrou resultados significativos e promissores. Isso evidencia que redes neurais convolucionais de baixo custo podem ser uma abordagem eficaz para o diagnóstico automatizado da patologia.

## Keywords

Leishmaniose Visceral Canina; Visão Computacional; Canine Visceral Leishmaniasis; Deep Learning; Computer Vision.

## 1. INTRODUÇÃO

A Leishmaniose é uma doença parasitária composta por diversas formas clínicas que podem variar tanto nos sintomas quanto na intensidade da doença. É causada por um protozoário chamado *Leishmania*. É uma das doenças tropicais amplamente negligenciadas em todo o mundo, conforme indicado pela Organização Mundial da Saúde [1]. Esta enfermidade é caracterizada como uma zoonose e tem um impacto significativo na saúde pública, pois a doença não recebe a atenção e nem os recursos para implementação de medidas preventivas adequadas. A transmissão da leishmaniose ocorre através da picada de flebotomíneos fêmeas, pequenos insetos que são reconhecidos como vetores do parasita.

Os cães são o principais hospedeiros e reservatórios da leishmaniose, como mencionado em Campino and Maia [2]. No processo de transmissão, os cães assumem a função efetiva de portadores no ciclo de disseminação do parasita para os seres humanos. A Leishmaniose Visceral (LV) é a forma

Permission to make digital or hard copies of all or part of this work for personal or classroom use is granted without fee provided that copies are not made or distributed for profit or commercial advantage and that copies bear this notice and the full citation on the first page. To copy otherwise, or republish, to post on servers or to redistribute to lists, requires prior specific permission and/or a fee.

mais grave da doença, podendo ser fatal em até 90% dos casos se não for tratada [3]. A Organização Mundial da Saúde (OMS) estima que a cada ano surgem entre 700.000 e 1.000.000 de novos casos de LV em humanos, com apenas 25% a 45% desses casos sendo notificados [4], evidenciando a gravidade e a amplitude do problema.

Os sintomas clínicos da LV em cães estão relacionados à genética, estado nutricional, carga parasitária e resposta imunológica específicas de cada animal, influenciando sua vulnerabilidade ou resistência à infecção [5]. A disseminação da doença infecta órgãos como medula óssea, baço, fígado e gânglios linfáticos [6]. Em humanos, os sintomas incluem febre prolongada, fraqueza, perda de apetite, anemia e aumento do fígado e baço [7]. Sem tratamento adequado, a doença pode causar a mortalidade do paciente, seja humano ou animal. Por isso, é importante realizar a detecção precoce e o tratamento em cães para controlar a disseminação da LV e diminuir sua incidência na população humana.

O método padrão para diagnosticar a LV consiste na análise parasitológica direta por meio de exames de microscopia, que busca parasitas em amostras de esfregaços e aspirados de órgãos. No entanto, essa avaliação pode ser demorada e cansativa para os profissionais de saúde, pois requer uma análise detalhada ao longo de várias horas consecutivas [8]. Com o intuito de simplificar esse processo, a aplicação de métodos computacionais para a automação do diagnóstico revela-se uma abordagem eficaz. A integração de técnicas avançadas de Visão Computacional (VC) destaca-se como uma alternativa para a detecção de doenças parasitológicas, com ênfase na LV [9]; [10]. Essas técnicas são alternativas menos trabalhosas e que demonstram uma precisão considerável na identificação de doenças.

Considerando a relevância de identificar a LV no estágio inicial, esta pesquisa propõe a utilização de técnicas avançadas de VC em conjunto com Redes Neurais Convolucionais (CNNs), com a finalidade de auxiliar na automação do diagnóstico da doença. O principal objetivo é realizar a classificação automática de macrófagos, células que atuam como ambientes propícios para a presença do parasita causador da LV. Essa abordagem visa contribuir para um diagnóstico mais rápido e eficaz. O trabalho segue a seguinte estrutura: A seção 2 apresenta os trabalhos e estudos relacionados, encontrados na literatura. A seção 3 apresenta a metodologia desenvolvida para este trabalho. A seção 4 apresenta os resultados obtidos com o desenvolvimento e aplicação da metodologia proposta. Por fim, a seção 5 apresenta as conclusões a respeito do estudo realizado.

## 2. TRABALHOS RELACIONADOS

Nesta seção serão apresentados e discutidos trabalhos voltados para a detecção automática de LV através de imagens do exame parasitológico. Irão ser abordados os objetivos primordiais de cada trabalho, as técnicas utilizadas, os resultados obtidos e as limitações encontradas em cada estudo.

O estudo proposto por Gonçalves *et al.* [11], automatiza a classificação da LV utilizando uma base de dados composta por 151 imagens, das quais 79 são positivas e 72 são negativas. Duas abordagens foram desenvolvidas: a primeira envolve uma CNN baseada na arquitetura LeNet, alcançando uma acurácia máxima de 78,7% e um recall máximo de 64%; enquanto a segunda emprega um extrator de características utilizando diversas CNNs pré-treinadas, como InceptionResNetV2, InceptionV3, NASNetLarge, ResNet152V2 e Xcep-

tion. A NASNetLarge demonstrou o melhor desempenho, com um recall de 75% e uma acurácia de 64%. Apesar dos resultados promissores, as redes utilizadas pelos autores precisam de um *hardware* mais eficiente em termos de recursos.

A metodologia empregada por Górriz *et al.* [12] adota a arquitetura U-net para realizar a detecção de parasitas de *Leishmania* em imagens microscópicas, visando classificá-los em amastigotas, promastigotas ou parasitas aderidos. O experimento foi conduzido com uma base de dados composta por 45 imagens, das quais 37 foram destinadas ao treinamento e 8 para teste. O F1-Score alcançado foi de 77,7%, um resultado significativo, apesar do conjunto de dados limitado disponível.

Já o estudo conduzido por Isaza-Jaimes *et al.* [13] efetivou uma abordagem computacional para a detecção automática de *Leishmania*, utilizando uma base de dados aberta contendo apenas 45 imagens. A técnica proposta alcançou uma taxa de reconhecimento de aproximadamente 80% dos parasitas, o que é considerável. No entanto, este trabalho não empregou técnicas de aprendizado profundo para a identificação dos parasitas em sua metodologia.

O trabalho de Neves *et al.* [14] apresenta um método de anotação e enumeração de parasitas e macrófagos em imagens fluorescentes infectadas por *Leishmania*. A base de dados é composta por 44 imagens, e a identificação de amastigotas resultou em 81,55 de precisão, Recall de 87,62% e F1-Score de 84,48%. No entanto, quando os parasitas estão muito próximos, podem ocorrer falhas de segmentação.

## 3. METODOLOGIA

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

### 3.1 Aquisição de Dados

A coleta da base de imagens para este estudo foi conduzida em colaboração com o Laboratório de Parasitologia, Ecologia e Doenças Negligenciadas (LAPEDONE), utilizando um microscópio focalizado em 40× equipado com uma câmera digital. A procura pelos parasitas foi realizada em lâminas contendo amostras biológicas retiradas da medula óssea do fêmur dos animais. Utilizou-se duas lâminas de animais diferentes, e o conjunto de dados obtido foi composto por 178 imagens de resolução 1920×1080. Neste conjunto, especialistas identificaram e marcaram as estruturas que são macrófagos, e as estruturas classificadas como não-macrófagos.

### 3.2 Pré-processamento

Durante a etapa de pré-processamento, foram utilizadas as marcações realizadas pelos especialistas para identificar os eixos de cada estrutura e recortar as regiões de interesse das imagens originais. Como as marcações das células não têm um tamanho padrão, foram adicionadas bordas contendo o valor 0 para preencher as imagens que não eram quadradas, sempre deixando a estrutura no centro da imagem. Em seguida todos os recortes foram redimensionados para 224×224, resultando assim em 137 imagens de macrófagos e 278 imagens de não macrófagos, totalizando 415 recortes. A base de dados obtida através dos recortes foi dividida em 60% para treino, 20% para teste e 10% para validação.

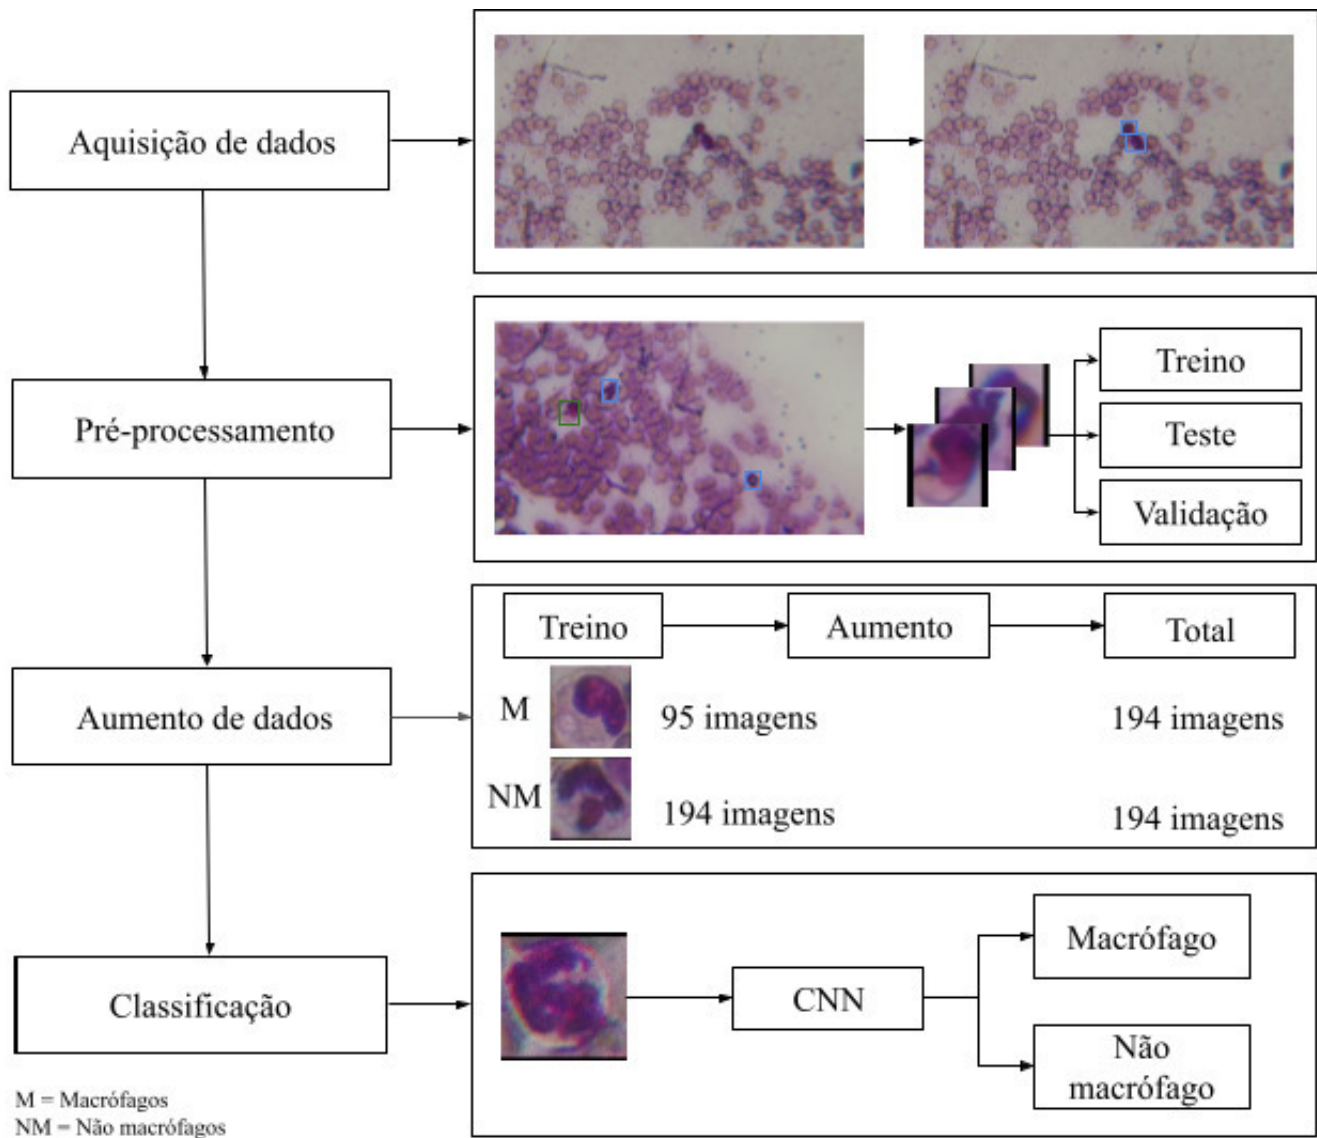


Figure 1: Fluxograma da metodologia proposta neste trabalho.

A Figura 2 mostra exemplos de recortes de macrófagos, e a Figura 3 apresenta exemplos de não-macrófagos.

### 3.3 Aumento de dados


Durante a metodologia, foram utilizadas técnicas de ampliação de dados para potencializar o treinamento das CNNs. As técnicas aplicadas foram a rotação aleatória nos eixos vertical e horizontal, e a aplicação de zoom aleatório nos valores entre 0 e 0,1, já que as estruturas não contém padrões definidos de formato ou tamanho. Essa técnica de aumento de dados foi utilizada apenas na classe de macrófagos a fim de diversificar a variedade dos dados de treinamento e balancear as duas bases, considerando as diferenças no número de imagens. Após a aplicação do aumento, cada classe da base de treino ficou com 194 imagens. A Figura 4 apresenta alguns exemplos de imagens sem e com a aplicação de aumento.

Além do aumento de dados, foi realizado um ajuste na

quantidade de imagens da base de teste com o intuito de igualar o número de imagens entre as duas classes. Essa adaptação foi efetuada na classe de não macrófagos de forma aleatória, assegurando que ambas as classes possuíssem a mesma quantidade de dados no conjunto de teste. Essa técnica foi aplicada para garantir uma distribuição balanceada entre as classes, contribuindo para uma avaliação justa e imparcial do desempenho do modelo em ambas as categorias.

### 3.4 Classificação de imagens

Neste trabalho, foram utilizados cinco modelos de CNNs como ferramentas para extrair atributos e realizar de forma precisa a classificação de imagens em relação a presença de macrófagos. CNNs são tipos de redes neurais artificiais que usam multicamadas complexas e profundas, capazes de reconhecer elementos em imagens [15]. Para este trabalho foram escolhidas as CNNs DenseNet201 (DN) [16], MobileNet (MN) [17]; MobileNetV2 (MNV2) [18]; ResNet50 (RN) [19];



**Figure 2: Estruturas classificadas como macrófagos.**

e ResNet50V2 (RNv2) [20] devido a sua quantidade de parâmetros e pela eficiência notável de tempo (ms) por etapa de inferência na GPU, como mostra a Tabela 1. Outro método também utilizado, foi a transferência de aprendizado, essa técnica foi usada em decorrência do número pequeno de imagens na base de dados e da significativa otimização no processo de treino das redes.

Durante o treinamento, foi usada a estratégia de congelamento das camadas convolucionais, preservando os extratores de características já estabelecidos na etapa de transferência de aprendizagem. Essa abordagem foi adotada com o intuito de evitar alterações que pudessem comprometer a qualidade dos resultados. Após à classificação, foi implementada a técnica de *fine tuning*. Essa prática envolveu

o descongelamento das camadas convolucionais, permitindo que o modelo fosse treinado integralmente com o conjunto de dados mencionado anteriormente. Os parâmetros escolhidos para o treinamento da rede exercem influência direta em sua performance. Neste estudo, conduzimos 30 épocas de treinamento e 60 épocas de *fine tuning*, adotando uma taxa de aprendizado de 0,01.

### 3.5 Avaliação de desempenho

A avaliação dos resultados obtidos nesse estudo foi conduzida por meio da aplicação de métricas reconhecidas no contexto da classificação de imagens, incluindo Perda, Acurácia, Precisão, Recall, F1-Score e Kappa [21]. Essas métricas oferecem informações importantes sobre o desempenho




Figure 3: Estruturas classificadas como não-macrófagos.

Table 1: Informações sobre as CNNs utilizadas durante este trabalho.

Modelo	Tamanho (MB)	Parâmetros	Tempo inferência (GPU)
DN	80	20,2M	6,7ms
RN	98	25,6M	4,6ms
RNV2	98	25,6M	4,4ms
MN	16	4,3M	3,4ms
MNV2	14	3,5M	3,8ms

do modelo. A seguir, fornecemos uma explicação sobre cada uma dessas métricas.

1. **Perda:**

$$\text{Perda} = \frac{1}{N} \sum_{i=1}^N L(y_i, \hat{y}_i)$$




Figure 4: Exemplo de aumentos aplicados nos dados.

A perda representa a discrepância entre as saídas previstas ( $\hat{y}_i$ ) e os rótulos verdadeiros ( $y_i$ ) em todo o conjunto de dados. O objetivo é minimizar essa perda durante o treinamento do modelo.

## 2. Acurácia:

$$\text{Acurácia} = \frac{TP + TN}{\text{Total}}$$

A Acurácia mede a proporção de predições corretas em relação ao número total de amostras. É uma medida

simples e amplamente utilizada, mas pode ser enganosa em conjuntos de dados desbalanceados.

## 3. Precisão:

$$\text{Precisão} = \frac{TP}{TP + FP}$$

A Precisão avalia a proporção de predições positivas corretas em relação ao número total de predições positivas feitas pelo modelo. É útil quando o foco está na minimização de falsos positivos.

#### 4. Recall:

$$\text{Recall} = \frac{TP}{TP + FN}$$

O Recall mede a proporção de instâncias positivas que foram corretamente identificadas pelo modelo. É uma métrica importante quando é crucial identificar todos os casos positivos.

#### 5. F1-Score:

$$\text{F1-Score} = 2 \times \frac{\text{Precisão} \times \text{Recall}}{\text{Precisão} + \text{Recall}}$$

O F1-Score é a média harmônica entre Precisão e Recall. Ele fornece um equilíbrio entre essas duas métricas e é útil quando há uma distribuição desigual de classes no conjunto de dados.

#### 6. Kappa:

$$\text{Kappa} = \frac{P(A) - P(E)}{1 - P(E)}$$

onde:

$$P(A) = \frac{\sum \text{Diagonal}}{\sum \text{Total}}$$

$$P(E) = \frac{\sum \text{Linha Total} \times \sum \text{Coluna Total}}{(\sum \text{Total})^2}$$

O coeficiente Kappa mede a concordância entre as classificações observadas e as esperadas, levando em consideração o acordo que poderia ser alcançado por acaso. É especialmente útil quando há mais de duas classes no problema de classificação.

Em resumo, a métrica de Perda é utilizada para avaliar o desempenho entre as previsões geradas pelo modelo e os valores reais correspondentes. Já a Acurácia é utilizada para avaliar o desempenho geral de classificação, representando a proporção de previsões corretas feitas pelo modelo em relação ao total de previsões. A Precisão, por sua vez, representa a proporção de previsões positivas corretas em relação ao total de previsões positivas feitas pelo modelo. O Recall, por sua definição, mede a taxa de previsões positivas corretas em relação ao total de amostras positivas reais. O F1-Score, incorpora a média harmônica entre a Precisão e o Recall, considerando tanto as previsões positivas corretas quanto a capacidade do modelo em identificar todas as amostras positivas. E por fim, o Kappa é uma métrica que avalia a concordância entre as predições do modelo e os valores verdadeiros, levando em consideração a probabilidade de acerto ao acaso. Essas métricas oferecem uma visão abrangente e detalhada do desempenho do modelo em relação às diferentes facetas da classificação de imagens.

## 4. RESULTADOS

Na metodologia usada durante este trabalho, o valor de entrada utilizada pelas imagens em cada CNN foi padronizada de 224×224 em formato RGB. A análise incluiu duas fases, antes e após a implementação do *fine tuning*. A Tabela 2 apresenta os resultados obtidos durante a primeira fase, apenas com o uso de CNNs, enquanto a Tabela 3 demonstra os resultados alcançados na segunda fase, após a aplicação do *fine tuning*. A Figura 5 mostra as imagens que a rede

Table 2: Resultados obtidos através da CNN.

CNN	Perda	Acc	Precisão	Recall	F1	kappa
DN	0,76	0,80	0,84	0,76	0,79	0,61
RN	0,34	<b>0,88</b>	<b>0,99</b>	0,80	0,87	<b>0,76</b>
RNV2	0,54	0,76	0,76	0,76	0,76	0,52
MN	0,38	0,85	0,89	0,80	0,84	0,71
MNV2	<b>0,27</b>	<b>0,88</b>	0,86	<b>0,90</b>	<b>0,88</b>	<b>0,76</b>

Table 3: Resultados obtidos após a aplicação do *fine tuning*.

CNN	Perda	Acc	Precisão	Recall	F1	kappa
DN	<b>0,36</b>	<b>0,85</b>	0,82	<b>0,90</b>	<b>0,86</b>	<b>0,71</b>
RN	0,44	0,80	0,75	<b>0,90</b>	0,82	0,61
RNV2	0,54	0,76	0,76	0,76	0,76	0,52
MN	0,40	0,83	0,81	0,85	0,83	0,66
MNV2	<b>0,36</b>	0,83	<b>0,85</b>	0,80	0,82	0,66

classificou incorretamente, e a Figura 6 mostra alguns dos exemplos de imagens que a rede classificou corretamente.

Ao realizar uma análise nos resultados obtidos na Tabela 2, é notável que durante a primeira fase do experimento a MobileNetV2 se destacou em quase todas as métricas em comparação com as outras CNNs, alcançando os resultados mais relevantes nas métricas de Perda, Acurácia, Recall, F1-Score e Kappa. Vale ressaltar que a única exceção foi a métrica de Precisão obtida com o uso da ResNet50. Essa notável diferença destaca a consistência do desempenho da MobileNetV2, evidenciando sua eficácia em relação às demais arquiteturas de CNN examinadas.


Table 4: Comparação das métricas deste trabalho com o estado da arte.

Estudo	Acc	Precisão	Recall	F1Score	kappa
[11]	0,78	<b>0,94</b>	0,64	0,76	0,58
[12]	-	0,75	0,82	0,77	-
[13]	-	0,78	-	-	-
[14]	-	0,81	0,87	0,84	-
<b>Este estudo</b>	<b>0,88</b>	0,86	<b>0,90</b>	<b>0,88</b>	<b>0,76</b>


Observando os resultados alcançados após a aplicação do *fine tuning*, é possível notar variações nos resultados, conforme apresentado na Tabela 3. A DenseNet201 evidencia um desempenho relevante em consideração com os resultados das demais CNNs em Acurácia, Recall, F1Score e Kappa, embora tenha demonstrado melhorias notáveis em Acurácia e Recall após o *fine tuning*, as métricas obtidas nessa fase permaneceram abaixo das métricas alcançadas pela MobileNetV2 na fase anterior do experimento.

Com relação às arquiteturas CNNs, a MobileNetV2 se mostrou mais confiável que as demais. De acordo com a Tabela 2, a MobileNetV2 obteve perda inferior a 30%, mais precisamente 27%, e mostrou eficiência com Acurácia, Precisão, Recall e F1-Score superiores a 85%. O valor do Kappa também foi significativo, sendo superior a 75%. Através desses resultados, é possível afirmar que métodos que utilizam baixo custo computacional podem obter resultados consideráveis, mesmo utilizando pouco poder de processamento de *hardware*. A Tabela 4 compara as métricas deste estudo com o estado da arte. Essa tabela apresenta diferenças significa-


Label: macrophage, Predito: Non-macrophages




Label: macrophage, Predito: Non-macrophages



Label: macrophage, Predito: Non-macrophages



Label: macrophage, Predito: Non-macrophages



Label: macrophage, Predito: Non-macrophages




Figure 5: Imagens que a rede classificou de forma incorreta.

tivas, destacando a MobileNetV2 como uma opção viável para aplicações onde recursos computacionais são restritos.

## 5. CONCLUSÃO

É possível concluir que o uso de CNNs de baixo custo computacional é um método eficaz e confiável para a classificação automática de LV. O trabalho proposto obteve resultados superiores aos trabalhos relacionados em termos de custo computacional, mesmo utilizando CNNs que demandam menos investimento computacional. Além disso, alcançou resultados superiores em quase todas as métricas em comparação com os trabalhos da literatura.

O método proposto demonstrou ser igualmente confiável e mais acessível quando comparado aos métodos do estado da arte. Isso se deve ao fato de possibilitar a classificação de LV utilizando um menor custo computacional, diminuindo o investimento em recursos computacionais ao utilizar o método proposto. Assim, este trabalho atingiu seu objetivo ao ser eficiente em termos de tempo, processamento, recursos e desempenho.

Como trabalhos futuros, pretendemos automatizar a detecção de LV implementando um detector juntamente com o uso de CNNs. Além disso, planejamos realizar a classificação utilizando CNNs com um custo computacional ainda menor, de forma que essa classificação possa ser realizada até mesmo em dispositivos móveis, como *smartphones*. Isso


abriria novas possibilidades de aplicações práticas e facilitaria o acesso à tecnologia de classificação automática de LV em diferentes cenários e contextos.

## Referências


- [1] E. C. WHO, *World Health Organ Tech Rep Ser*, 2010, **949**, 22–26.
- [2] L. Campino and C. Maia, *Acta medica portuguesa*, 2010, **23**, 859–64.
- [3] C. d. A. Gonçalves, A. L. Borges, V. B. L. Dias, N. B. de Andrade, B. G. A. Aguiar and P. Negligenciados, 2022.
- [4] O. M. de Saúde, *Leishmaniose*, <https://www.who.int/news-room/fact-sheets/detail/leishmaniasis>, Acessado em 11 de janeiro de 2024.
- [5] G. Baneth, in *Greene: Doenças infecciosas do cão e do gato*, Saunders Elsevier, Saint Louis, 3rd edn., 2006, pp. 685–698.
- [6] C. I. L. S. Álvaro, *M.Sc. thesis*, 2022.
- [7] R. Kumar and S. Nylén, *Frontiers in immunology*, 2012, **3**, 251.




Label: Non-macrophages, Predito: Non-macrophages




Label: Non-macrophages, Predito: Non-macrophages




Label: Non-macrophages, Predito: Non-macrophages




Label: Non-macrophages, Predito: Non-macrophages



Label: Non-macrophages, Predito: Non-macrophages



Label: Non-macrophages, Predito: Non-macrophages



Label: Non-macrophages, Predito: Non-macrophages



Label: Non-macrophages, Predito: Non-macrophages



Figure 6: Imagens que a rede classificou de forma correta.

- [8] R. R. Silva, F. H. Araujo, D. M. Ushizima, A. G. Bianchi, C. M. Carneiro and F. N. Medeiros, *Journal of Visual Communication and Image Representation*, 2019, **62**, 105–116.
- [9] R. R. V. e Silva, F. H. D. de Araujo, L. M. R. dos Santos, R. M. S. Veras and F. N. de Medeiros, *IEEE Latin America Transactions*, 2016, **14**, 2446–2454.
- [10] C. Gonçalves, A. Borges, A. Rodrigues, N. Andrade, M. Lemus, B. Aguiar and R. Silva, *IEEE Latin America Transactions*, 2023, **21**, 310–319.
- [11] C. d. A. Gonçalves, A. L. Borges, V. B. L. Dias, N. B. de Andrade, B. G. A. Aguiar and P. Negligenciados, 2022.
- [12] M. Górriz, A. Aparicio, B. Raventós, V. Vilaplana, E. Sayrol and D. López-Codina, International Conference on Articulated Motion and Deformable Objects, 2018, pp. 53–62.
- [13] A. Isaza-Jaimes, V. Bermúdez, A. Bravo, J. Sierra Castriello, J. D. Hernández Lalinde, C. A. Fossi, A. Flórez and J. E. Rodríguez, 2020.
- [14] J. C. Neves, H. Castro, A. Tomás, M. Coimbra and H. Proença, *Cytometry Part A*, 2014, **85**, 491–500.
- [15] I. Goodfellow, Y. Bengio and A. Courville, *Deep learning*, MIT press, 2016.
- [16] G. Huang, Z. Liu, L. van der Maaten and K. Q. Weinberger, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017.
- [17] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto and H. Adam, *MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications*, 2017.

- [18] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov and L.-C. Chen, *MobileNetV2: Inverted Residuals and Linear Bottlenecks*, 2019.
- [19] K. He, X. Zhang, S. Ren and J. Sun, *Deep Residual Learning for Image Recognition*, 2015.
- [20] K. He, X. Zhang, S. Ren and J. Sun, *Identity Mappings in Deep Residual Networks*, 2016.
- [21] J. L. Fleiss, B. Levin and M. C. Paik, *Statistical methods for rates and proportions*, John Wiley & Sons, 2013.