



**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE MEDICINA
PROGRAMA DE PÓS-GRADUAÇÃO EM MEDICINA TROPICAL**

JOSÉ FABRÍCIO DE CARVALHO LEAL

INOVAÇÃO NA DERMATOLOGIA TROPICAL:
identificação automática de lesões de leishmaniose cutânea utilizando
inteligência artificial

**BRASÍLIA – DF
2024**


JOSÉ FABRÍCIO DE CARVALHO LEAL

INOVAÇÃO NA DERMATOLOGIA TROPICAL:

identificação automática de lesões de leishmaniose cutânea utilizando inteligência artificial

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Medicina Tropical da Universidade da Brasília para a obtenção do título de Mestre em Medicina Tropical, na área de concentração: Biologia das Doenças Infecciosas e Parasitárias (DIP).

Orientador: Rodrigo Gurgel Gonçalves



**BRASÍLIA – DF
2024**

L435i Leal, José Fabrício de Carvalho
INOVAÇÃO NA DERMATOLOGIA TROPICAL: identificação
automática de lesões de leishmaniose cutânea utilizando
inteligência artificial / José Fabrício de Carvalho Leal;
orientador Rodrigo Gurgel-Gonçalves. -- Brasília, 2024.
137 p.

Dissertação (Mestrado em Medicina Tropical) --
Universidade de Brasília, 2024.

1. Leishmaniose cutânea. 2. Diagnóstico dermatológico. 3.
Doença negligenciada. 4. Aprendizado de máquina. 5.
Inteligência artificial. I. Gurgel-Gonçalves, Rodrigo,
orient. II. Título.

JOSÉ FABRÍCIO DE CARVALHO LEAL

INOVAÇÃO NA DERMATOLOGIA TROPICAL:
identificação automática de lesões de leishmaniose cutânea utilizando
inteligência artificial

Banca examinadora:

Prof. Dr. Rodrigo Gurgel Gonçalves - Presidente
Universidade de Brasília - UnB

Prof. Dr. Gerson Oliveira Penna - Membro Titular
Universidade de Brasília - UnB

Prof^a. Dr^a. Márcia Hueb - Membro Titular
Universidade Federal do Mato Grosso - UFMT

Prof. Dr. Ciro Martins Gomes - Suplente
Universidade de Brasília - UnB

Dedico esta dissertação aos meus pais, Marciela e Francisco, ao meu irmão, Fred, e aos demais familiares, cujo amor, apoio e encorajamento foram fundamentais ao longo desta jornada.

AGRADECIMENTOS

Agradeço a Deus pela dádiva da vida, por me guiar e iluminar em cada passo dessa trajetória acadêmica e, principalmente, por ter me concedido sabedoria, saúde, paciência e força para persistir durante este caminho que, por muitas vezes, foi difícil e tortuoso.

Aos meus queridos pais, Marciela e Francisco, pelo amor incondicional, pelas preocupações, orações, apoio incansável e por acreditarem nos meus sonhos. Ao meu irmão Fred, a quem tanto amo.

Aos demais familiares pela força e apoio constante, especialmente às minhas tias Flávia, Marciana e Magali, aos meus queridos avós Moacir, Petronila e José, e às minhas tias Marinalva, Sônia e Wilma.

Ao Prof. Dr. Rodrigo Gurgel Gonçalves, meu orientador, pelo acolhimento, sabedoria, paciência, disponibilidade, motivação e orientações excepcionais. Sobretudo, pelo comprometimento, incentivo e confiança nos meus trabalhos. Você é um exemplo de pesquisador!

Ao Prof. Dr. Daniel Holanda Barroso, pelos valiosos ensinamentos no campo da dermatologia e da Leishmaniose Cutânea, pela paciência, dedicação, confiança e estímulo que foram fundamentais para o meu desenvolvimento.

Aos professores Dr. Gerson Oliveira Penna, Dra. Márcia Hueb e Dr. Ciro Martins Gomes, membros da banca, por aceitarem contribuir valiosamente com esta dissertação. A colaboração de vocês é fundamental para o enriquecimento desse trabalho.

Ao Hospital Universitário de Brasília (HUB) e aos pacientes que fizeram parte dessa pesquisa. A realização desse estudo foi viabilizada graças à colaboração de vocês!

Ao Prof. Dr. Marcos Takashi Obara, pelos ensinamentos, conselhos e entusiasmo.

Ao Prof. Dr. Vinícius Lima, amigo de pesquisa, pelo conhecimento compartilhado, paciência e boas risadas que tornaram essa jornada mais leve.

À Taís Araújo, Isadora Ribeiro, Elias Neves e Patrícia Gomes pelas experiências acadêmicas, ensinamentos e bons momentos de alegria no Laboratório de Parasitologia Médica e Biologia de Vetores.

À Natália Trindade, pelo apoio constante, pela oportunidade de orientar e compartilhar conhecimento. Além disso, agradeço a oportunidade de aprender contigo.

À Luana Morais e Mariel, irmãs que ganhei na pós-graduação, pelo acolhimento em Brasília, pelo carinho, apoio mútuo nos desafios acadêmicos e pelas risadas compartilhadas. Vocês trouxeram uma dimensão única à minha experiência acadêmica e pessoal!

À Vitória Pessoa, amiga de turma e um grande presente do mestrado, pelo carinho, amizade, motivação constante e experiências compartilhadas. Você é luz! À Thauana Vieira, Brenda Reis, Isadora Moura e Saimara, pela disponibilidade, escuta atenciosa, palavras amigas e conselhos nos momentos de aflição.

À Jean, Mayla, Matheus e Thayse, amigos que ganhei na moradia estudantil da pós-graduação, pelas vivências, conselhos, compreensão, colo amigo e ensinamentos. Que nossos caminhos continuem se cruzando, pois vocês foram fundamentais nessa etapa da minha vida.

À Prof. Dra. Ana Carolina Landim Pacheco e Prof. Dra. Marcia Maria Mendes Marques, do Curso de Ciências Biológicas da UFPI - CSHNB, pelos conselhos, orientações, confiança e incentivo à pesquisa. Vocês foram essenciais na minha trajetória acadêmica.

À Universidade de Brasília e a Diretoria de Desenvolvimento Social, pelos auxílios alimentação e moradia que possibilitaram a minha permanência na pós-graduação, estando distante das minhas origens.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela bolsa. Ao auxílio PROAP/CAPES por todo apoio financeiro que contribuiu para o desenvolvimento deste trabalho.

Por fim, agradeço aos familiares e amigos não citados, aos meus ex-professores da educação básica e aos belenenses (Belém do Piauí) que acreditam e torcem por mim. Muito obrigado!

“Os benefícios da ciência não são para os cientistas, e sim para humanidade!”

(Louis Pasteur)

LISTA DE QUADROS

Quadro 1 - Espécies de <i>Leishmania</i> spp. que causam leishmanioses no Brasil.....	18
--	----

LISTA DE TABELAS

Tabela 1 - Número de imagens de lesões cutâneas relacionados ao grupo de classificação, segundo a etiologia.....	50
---	----

LISTA DE FIGURAS

Figura 1 – Situação de endemicidade de leishmaniose cutânea no mundo, em 2020.....	20
Figura 2 – Espécies de <i>Leishmania</i> causadoras de leishmaniose cutânea no Brasil.....	21
Figura 3 – Ciclos de transmissão da leishmaniose cutânea.....	22
Figura 4 – Lesões ulceradas, arredondadas e com bordas bem elevadas de leishmaniose cutânea.....	23
Figura 5 – Leishmaniose cutânea disseminada.....	24
Figura 6 – Cicatriz atrófica de paciente que teve leishmaniose cutânea.....	25
Figura 7 – Leishmaniose cutânea erisipelóide.....	27
Figura 8 – Leishmaniose cutânea psoriasiforme.....	28
Figura 9 – Leishmaniose cutânea acneiforme	29
Figura 10 – Forma esporotricóide de leishmaniose cutânea.....	29
Figura 11 – Linha do tempo de momentos importantes no desenvolvimento da Inteligência Artificial.....	33
Figura 12 – Esquema ilustrando como um algoritmo de aprendizado de máquina treina em um grande conjunto de dados, associando dados a rótulo (aprendizado supervisionado).....	34
Figura 13 – Comparação entre neurônios biológicos e redes neurais artificiais. (a) estrutura de um neurônio biológico; (b) estrutura de um neurônio artificial; (c) e (d) ilustram as redes biológica e artificial, respectivamente.....	37
Figura 14 – Representação esquemática de como as tarefas de classificação de imagens são realizadas em redes neurais convolucionais.....	38
Figura 15 – Aplicações da inteligência artificial na medicina.....	40
Figura 16 – Fluxo de diagnóstico de pacientes com LC atendidos no Ambulatório de Dermatologia do HUB.....	49
Figura 17 – Fluxo de execução resumindo a metodologia adotada. (A) Fotografias das lesões cutâneas dos pacientes; (B) Classificação em pastas,	

redimensionamento de imagens e simulações; (C) Análise do desempenho do algoritmo.....	51
Figura 18 – Arquitetura do AlexNet.....	52
Figura 19 – Esquema usual de uma rede neural convolucional à esquerda. Esquema com <i>dropout</i> à direita, contendo alguns neurônios inativos.....	53
Figura 20 – Exemplos de lesões de leishmaniose cutânea utilizadas no estudo.....	54
Figura 21 - Exemplos de outros tipos de lesões cutâneas. (A) ectima; (B) erisipela; (C) piodermite; (D) sífilis terciária; (E) esporotricose; (F) líquen plano; (G) líquen simples crônico; (H) tinea corporis; (I) CEC; (J) ceratose actínica; (K) poroceratose; (L) insuficiência venosa.....	54
Figura 22 - Progresso de treino da rede AlexNet. São apresentadas curvas de acurácia de treinamento, acurácia de validação, perda de treinamento e a perda de validação, com suavização aplicada para destacar tendências gerais no decorrer das iterações. O eixo horizontal representa as iterações, enquanto o eixo vertical representa os valores correspondentes das métricas.....	56
Figura 23 - Matrizes de confusão das simulações (lesões de LC × lesões de outras dermatoses) mostrando algumas das imagens de LC que foram erroneamente identificadas como outros tipos de lesões pela AlexNet e algumas imagens de outras dermatoses que foram identificadas como LC pela rede. (A) simulação 1; (B) simulação 2; (C) simulação 3.....	58
Figura 24 - Porcentagem de imagens de dermatoses identificadas incorretamente pela rede AlexNet. Acima de cada barra há o número exato da quantidade de identificações como LC.....	59
Figura 25 - Acurácia, sensibilidade e especificidade da rede AlexNet para identificação de imagens de lesões de LC com intervalos de confiança (barras) de Wilson de 95%.....	60

LISTA DE ABREVIações

- ANN's** – Redes neurais artificiais (*Artificial Neural Networks*)
- CBC** – Carcinoma basocelular
- CEC** – Carcinoma espinocelular
- CNN's** – Redes Neurais Convolucionais (*Convolutional Neural Networks*)
- DL** – Aprendizado profundo (*Deep Learning*)
- DTN's** – Doenças Tropicais Negligenciadas
- HUB** – Hospital Universitário de Brasília
- IA** – Inteligência artificial
- IC** – Intervalo de confiança
- IDRM** – Intradermorreação de Montenegro
- LC** – Leishmaniose cutânea
- LCD** – Leishmaniose cutânea difusa
- LD** – Leishmaniose disseminada
- LMC** – Leishmaniose mucocutânea
- LT** – Leishmaniose tegumentar
- LV** – Leishmaniose visceral
- ML** – Aprendizado de máquina (*Machine Learning*)
- PCR** – Reação em cadeia de polimerase
- RGB** – Vermelho-verde-azul
- ReLU** – Unidade Linear Retificada (*Rectified Linear Unit*)
- Sim** - Simulação
- UTI** – Unidade de Terapia Intensiva

FINANCIAMENTO

Apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) através da bolsa de estudo para auxílio nas atividades envolvidas no mestrado. Além do PROAP/CAPES, auxílio financeiro a discentes de pós-graduação para o desenvolvimento de dissertações e de teses.

SUMÁRIO

1	INTRODUÇÃO	18
1.1	Leishmaniose	18
1.1.1	Leishmaniose Cutânea	20
1.2	Inteligência artificial	32
1.2.1	Aprendizado de máquina	34
1.2.2	Aprendizagem profunda e Redes Neurais	36
1.3	Avanços da inteligência artificial na medicina	39
1.3.1	Inteligência artificial na dermatologia	43
1.3.2	Inteligência artificial e leishmaniose cutânea	45
2	JUSTIFICATIVA	46
3	OBJETIVOS	48
3.1	Geral	48
3.2	Específicos	48
4	MATERIAIS E MÉTODOS	49
4.1	Desenho do Estudo e Banco de Imagens	49
4.2	Algoritmo: treino e teste	52
4.3	Análise dos dados	55
4.4	Consideração Ética	56
5	RESULTADOS	57
5.1	Treino	57
5.2	Desempenho do AlexNet	57
6	DISCUSSÃO	62
7	CONCLUSÃO	68
	REFERÊNCIAS	69
	APÊNDICE - Tabelas com as simulações e predições do algoritmo	81
	ANEXO A - Aprovação do Comitê de Ética em Pesquisa	117
	ANEXO B - Artigo Publicado	123

RESUMO

A leishmaniose cutânea (LC) é uma doença parasitária que afeta cerca de um milhão de indivíduos em todo o mundo, especialmente em regiões tropicais e subtropicais. O polimorfismo da LC dificulta o diagnóstico nos serviços de saúde, pois as lesões podem ser confundidas com outras dermatoses, como esporotricose, paracocidiomicose e insuficiência venosa. Além disso, o diagnóstico da LC depende de especialistas como dermatologistas e infectologistas experientes e de procedimentos laboratoriais, tornando o processo de diagnóstico lento e, muitas vezes, tardio. A identificação automatizada de doenças de pele baseada em aprendizagem profunda (DL) tem sido aplicada para auxiliar o diagnóstico. Neste estudo, avaliamos o desempenho do AlexNet, um algoritmo de DL, para identificar imagens de lesões de LC em pacientes atendidos no Distrito Federal, procedentes da região Centro-Oeste do Brasil. Utilizamos um conjunto de 2.458 imagens (até 10 de cada lesão) obtidas de pacientes atendidos entre 2015 e 2022 no Ambulatório de Dermatologia do Hospital Universitário de Brasília (HUB). Organizamos um banco de imagens de dermatoses, as quais foram diagnosticadas usando um padrão de referência composto seguindo a classificação operacional do HUB, baseado em sintomas clínicos compatíveis, testes não parasitológicos (imunofluorescência indireta, intradermorreação de Montenegro) ou teste parasitológico (qPCR, cultura, histopatologia ou esfregaço com amastigotas), permitindo uma classificação confiável de cada imagem. Do total de imagens, 80% foram utilizadas para treinamento, 10% para testagem e 10% para validação do AlexNet na tarefa de identificar imagens de lesões de LC. Realizamos três simulações e treinamos AlexNet para diferenciar a LC de outras 26 dermatoses (por exemplo, cromomicose, piodermite, insuficiência venosa). Obtivemos uma acurácia média de 95,04% (Intervalo de Confiança de 95%: 93,81–96,04), indicando um excelente desempenho do AlexNet na identificação de imagens de lesões de LC. Dentre as 60 imagens de lesões de outras dermatoses que foram confundidas com LC nas três simulações, as doenças de pele que apresentaram o maior percentual de erros foram: hanseníase, ectima, carcinoma basocelular, erisipela e líquen plano. Concluímos que a identificação automatizada de LC usando AlexNet tem o potencial de auxiliar os clínicos no diagnóstico de lesões cutâneas, podendo contribuir para o diagnóstico precoce, diminuindo os impactos negativos na qualidade de vida dos indivíduos afetados, e o tratamento oportuno da LC. Esses resultados contribuem para o desenvolvimento de um aplicativo móvel para auxiliar no diagnóstico da LC nos serviços de saúde. Além disso, essa dissertação representa um avanço na aplicação do DL na dermatologia tropical, como uma nova ferramenta diagnóstica na LC.

Palavras-chave: Dermatologia; leishmaniose; diagnóstico; AlexNet; aprendizado de máquina; imagens.

ABSTRACT

Cutaneous leishmaniasis (CL) is a parasitic disease that affects about 1 million people worldwide, mainly in tropical and subtropical regions. The polymorphism of CL makes diagnosis challenging in health services, as the lesions can be confused with other dermatoses such as sporotrichosis, paracoccidioidomycosis, and venous insufficiency. Moreover, the diagnosis of CL depends on specialists such as experienced dermatologists and infectious disease specialists and laboratory procedures, making the diagnosis process slow and often delayed. Automated identification of skin diseases based on deep learning (DL) has been applied to aid diagnosis. In this study, we evaluated the performance of AlexNet, a DL algorithm, to identify images of CL lesions in patients treated in the Federal District, coming from the Midwest region of Brazil. We used a set of 2458 images (up to 10 of each lesion) obtained from patients treated between 2015 and 2022 at the Dermatology Outpatient Clinic of the University Hospital of Brasília (HUB). We organized an image bank of dermatoses diagnosed using a composite reference standard following the operational classification of the HUB, based on compatible clinical symptoms, non-parasitological tests (indirect immunofluorescence, Montenegro intradermal reaction) or parasitological test (qPCR, culture, histopathology, or amastigote smear), allowing a reliable classification of each image. Of the total images, 80% were used for training, 10% for testing and 10% for AlexNet validation in the task of identifying images of CL lesions. We performed three simulations and trained AlexNet to differentiate CL from 26 other dermatoses (e.g., chromomycosis, pyoderma, venous insufficiency). We obtained a mean accuracy of 95.04% (95% confidence interval: 93.81–96.04), indicating an excellent performance of AlexNet in the identification of images of CL lesions. Out of the 60 images of lesions from other dermatoses that were misidentified as CL in the three simulations, the skin diseases with the highest percentage of errors were: leprosy, ecthyma, basal cell carcinoma, erysipelas, and lichen planus. We conclude that the automated identification of CL using AlexNet has the potential to assist clinicians in the diagnosis of skin lesions. This may contribute to early diagnosis and timely treatment of CL, ultimately decreasing the negative impact on the quality of life of patients. These results contribute to the development of a mobile application to assist in the diagnosis of CL in healthcare settings. Furthermore, our study is a significant advancement in the use of DL in tropical dermatology as a novel diagnostic tool for CL.

Keywords: dermatology; leishmaniasis; diagnosis; AlexNet; machine learning; pictures.

1 INTRODUÇÃO

1.1 Leishmaniose

As leishmanioses são parasitoses causadas por mais de 20 espécies de protozoários flagelados (tripanosomatídeos) do gênero *Leishmania*, transmitidos por flebotomíneos fêmeas, principalmente dos gêneros *Lutzomyia*, *Nyssomyia* (Novo Mundo) e *Phlebotomus* (Velho Mundo), conhecidos como mosquitos-palha. As leishmanioses são amplamente distribuídas nos trópicos, subtropicais e sul da Europa, em áreas urbanas, periurbanas, rurais e vários ecossistemas, desde florestas tropicais nas Américas a desertos no oeste da Ásia. São encontradas em 99 países da África, Ásia, América e Europa, entretanto, mais de 90% dos novos casos ocorrem em apenas 13 desses países (Afeganistão, Argélia, Bangladesh, Bolívia, Brasil, Colômbia, Etiópia, Índia, Irã, Peru, Sudão do Sul, Sudão e Síria) (Herwaldt, 1999; Steverding, 2017; Torres-Guerrero *et al.*, 2017; Burza; Croft; Boelaert, 2018).

Historicamente, existem evidências que a doença acompanha o homem desde a antiguidade, existindo relatos e diversas descrições encontrados em escritos antigos e achados moleculares de material arqueológico datando de 2.500 a.C. (Akhoundi *et al.*, 2016). A identificação de *Leishmania* como agente etiológico teve início no século XX, no ano de 1903, quando o médico William Leishman identificou o parasito em esfregaços sanguíneos do baço de um paciente na Índia. Em reconhecimento às contribuições de Leishman para a identificação do parasito intracelular obrigatório, a doença foi nomeada “leishmaniose” (Herwaldt 1999; Akhoundi *et al.*, 2016; Steverding, 2017; Jogas, 2017). Cerca de 53 espécies do gênero *Leishmania* já foram descritas em todo o mundo, destas 31 são conhecidas como parasitos de mamíferos e 22 são espécies patogênicas para o ser humano. Entre essas 22 espécies, 15 foram identificadas nas américas e estão agrupadas nos subgêneros *Leishmania* e *Viannia* (Akhoundi *et al.*, 2016; OPAS, 2023). No Brasil, oito espécies já foram identificadas (Quadro

1), sendo duas do subgênero *Leishmania* e seis do subgênero *Viannia* (Conceição-Silva; Alves, 2014; Anversa *et al.*, 2018).

Quadro 1 - Espécies de *Leishmania* spp. que causam leishmanioses no Brasil.

Espécie de <i>Leishmania</i>	Forma Clínica
<i>L. (V.) braziliensis</i>	LC, LD, LMC,
<i>L. (V.) guyanensis</i>	LC, LMC
<i>L. (V.) lainsoni</i> *	LC
<i>L. (V.) naiffi</i> *	LC
<i>L. (V.) shawi</i> *	LC
<i>L. (V.) lindenbergi</i> *	LC
<i>L. (L.) amazonensis</i>	LC, LD, LMC, LCD
<i>L. (L.) infantum (chagasi)</i>	LV

*Menos frequentes.

Abreviações: LC = leishmaniose cutânea; LD = leishmaniose disseminada; LMC = leishmaniose mucocutânea; LCD = leishmaniose cutânea difusa; LV = leishmaniose visceral.

Há ampla diversidade de manifestações clínicas com diferentes níveis de gravidade, desde lesões cutâneas até doença visceral com desfechos potencialmente fatais, que dependem da espécie de *Leishmania* envolvida e de outros fatores, como carga parasitária e resposta imune do hospedeiro (Torres-Guerrero *et al.*, 2017; Burza; Croft; Boelaert, 2018). Essas espécies estão distribuídas em diversas regiões geográficas e podem se apresentar de duas formas clínicas principais: a leishmaniose visceral (LV) e a leishmaniose tegumentar (LT), essa última é considerada a sexta doença dermatológica mais prevalente no mundo e apresenta um amplo espectro de manifestações clínicas: leishmaniose cutânea (LC), leishmaniose disseminada (LD), leishmaniose cutânea difusa (LCD) e leishmaniose mucocutânea (LMC) (Quadro 1). Os diferentes tipos de leishmaniose duram meses ou anos, causando estigmatização, estresse, mutilação, fraqueza, prostração ou até mesmo a morte. Atualmente, mais de um bilhão de pessoas vivem em áreas endêmicas para leishmanioses, assim sendo, estão em risco de infecção (Carvalho *et al.*, 2022; WHO, 2023). Além disso, as leishmanioses estão associadas à pobreza, problemas ambientais e climáticos e diversos fatores aumentam o risco de infecção, como más condições de moradia, saneamento ambiental, falta de medidas de proteção individual, o que coloca os indivíduos em contato com o flebotomíneos infectados (WHO, 2023).

1.1.1 Leishmaniose Cutânea

De acordo com Eduardo Rabello, é possível afirmar que a leishmaniose cutânea existia no Brasil desde 1827, e que era designada por expressões regionais como 'feridas bravas', 'botão da Bahia', 'buba-brasiliana' e 'úlcera de Baurú' (Vale; Furtado, 2005). Atualmente, sabe-se que a LC é uma protozoose infecciosa, não contagiosa e de transmissão vetorial, sendo considerada a forma clínica mais comum (Carvalho *et al.*, 2022). A Organização Mundial de Saúde estima que cerca de 600.000 a 1 milhão de casos novos ocorram anualmente em todo o mundo, mas apenas cerca de 200.000 são notificados (WHO, 2023).

Segundo o Ministério da Saúde, entre 2015 e 2020 mais de 15 mil indivíduos/ano apresentaram LC no país e o maior número de casos registrados foi nas regiões Norte, Centro-Oeste e Nordeste, respectivamente. A epidemiologia da doença mostra que o Brasil foi considerado um dos sete países com o maior número de casos novos para LC em 2020 (Figura 1). Em 2022, a Organização Mundial da Saúde considerou 90 países como endêmicos para LC, no qual nove notificam 85% dos casos, dos quais três estão nas Américas: Brasil, Colômbia e Peru. Além disso, no mesmo ano, o Brasil registrou 12.953 casos (OPAS, 2023; WHO, 2023; Brasil, 2023).

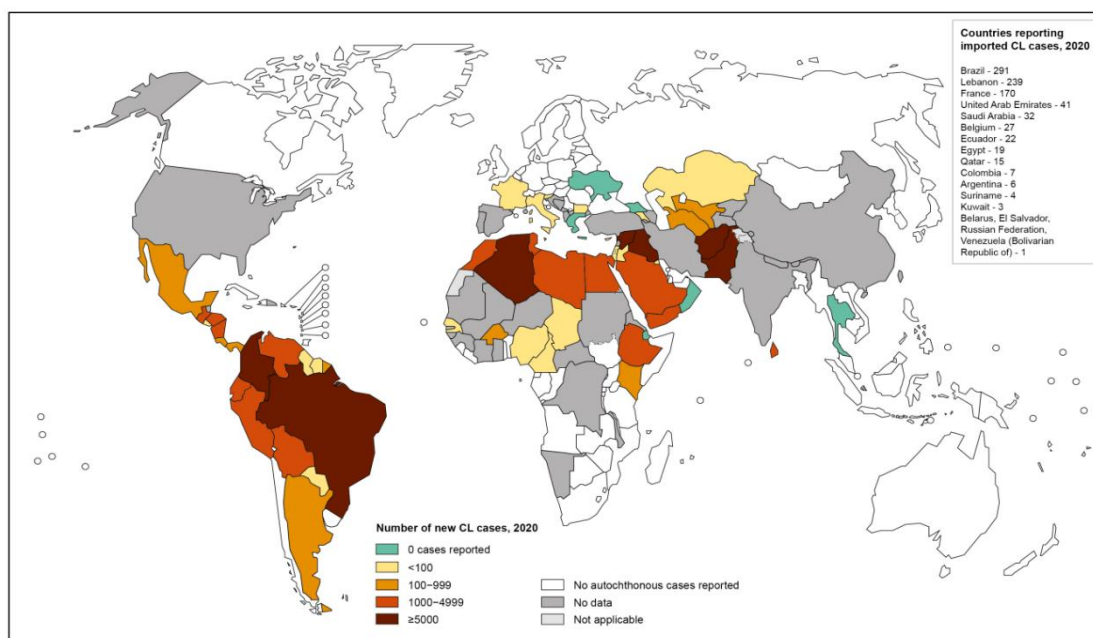


Figura 1 – Situação de endemicidade de leishmaniose cutânea no mundo, em 2020. Fonte: OMS. Disponível em: <https://cdn.who.int/media/docs/default-source/2021-dha-docs/leishmaniasis_cl_2020.pdf?sfvrsn=716850a8_9>. Acesso em: 01 dez. 2023.

No Brasil, já foram identificadas sete espécies dermatrópicas de *Leishmania* causadoras de LC (Figura 2), seis são do subgênero *Viannia* e uma do subgênero *Leishmania*. As três principais espécies são: *L. (V.) braziliensis*, *L. (L.) amazonensis* e *L. (V.) guyanensis*. *L. (V.) braziliensis* está amplamente distribuída em todo país e foi a primeira espécie descrita como agente etiológico da LC, sendo considerada a mais importante em toda América Latina. As outras espécies foram identificadas em estados das regiões Norte e Nordeste: *L. (V.) lainsoni*, *L. (V.) naiffi*, *L. (V.) lindenbergi* e *L. (V.) shawi*. Logo, cada espécie apresenta características específicas relacionadas às manifestações clínicas, vetores, reservatórios, padrões epidemiológicos, à distribuição geográfica e à resposta terapêutica (Vale; Furtado, 2005; Mota; Miranda, 2011; Brasil, 2017; Anversa *et al.*, 2018).

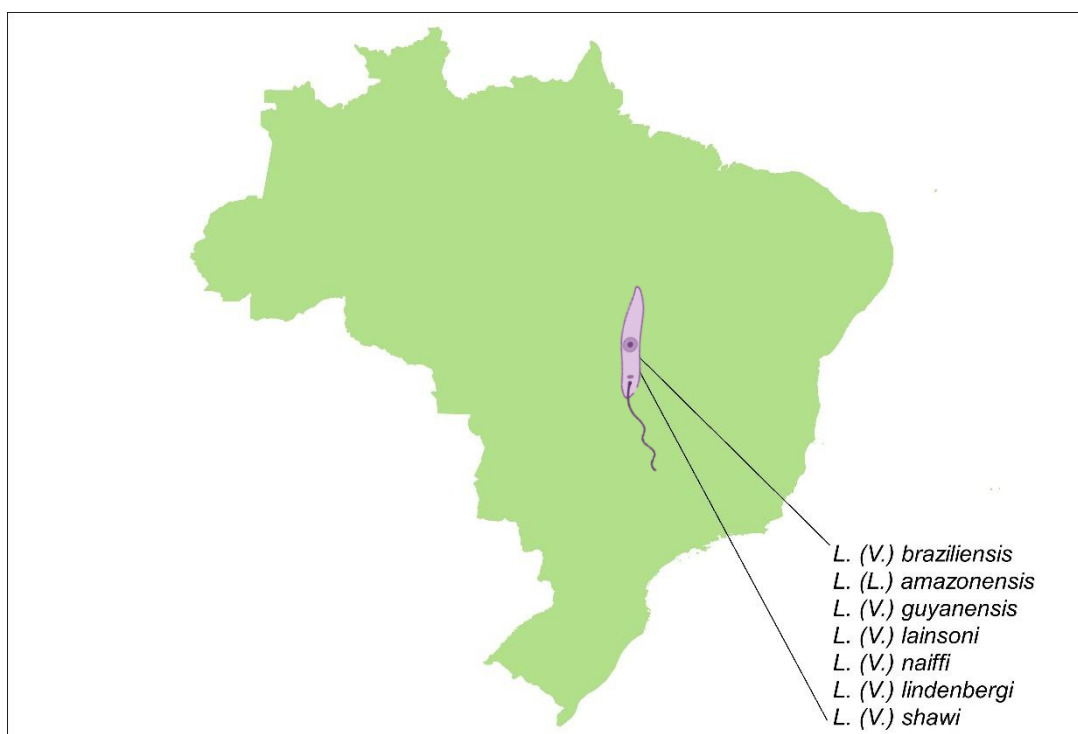


Figura 2 - Espécies de *Leishmania* causadoras de leishmaniose cutânea no Brasil. Fonte: Elaborado pelo autor (2024).

A pele é a principal porta de entrada da LC. A transmissão ocorre através da picada de flebotomíneos, popularmente conhecidos como mosquito-palha, taturiquira, birigui, asa branca, cangalhinha, entre outros (Brasil, 2017). No Brasil, as principais espécies envolvidas são *Nyssomyia whitmani*, *Ny. intermedia*, *Ny. umbratilis*, *Psychocopygus wellcomei*, *Bichromomyia flaviscutellata* e *Migonemyia migonei* (Brasil, 2023). A LC é classicamente zoonótica, a fêmea do flebotomíneo é infectada durante a alimentação sanguínea de um vertebrado infectado, posteriormente, o inseto infecta outro vertebrado através da picada, sendo que os seres humanos são hospedeiros acidentais da infecção, e outros mamíferos (como roedores e canídeos) são hospedeiros reservatórios. Também existe a forma antroponótica descrita no Velho Mundo, a qual é transmitida de humano para humano através do vetor, observada principalmente em áreas urbanas - Figura 3 (Herwaldt, 1999; Mokni, 2019; Gurel; Tekin; Uzun, 2020).




Figura 3 – Ciclos de transmissão da leishmaniose cutânea. Fonte: Elaborado pelo autor (2024).

A LC é caracterizada pela presença de lesão exclusivamente cutânea no local da picada do flebotomíneo, geralmente, em áreas expostas, como face, membros superiores e inferiores. As lesões de LC variam em gravidade (tamanho da lesão), aparência clínica e tempo para a cura. Indivíduos com LC podem apresentar uma ou mais lesões de pele, iniciando com aspecto nodular ou no formato de mácula com eritema e edema, que evolui para pápula, podendo ser confundida com picada de inseto. A lesão aumenta de tamanho e profundidade progressivamente (lesões pápulo-tuberosas) e, após o período de incubação com média de 10 dias a 3 meses, evolui para uma úlcera com formato arredondado, base eritematosa e bordas elevadas bem definidas (Figura 4). Além disso, é infiltrada, apresenta consistência firme e fundo eritematoso com granulações. Geralmente, é indolor, entretanto, se houver infecção secundária associada por outros agentes microbianos, pode ocorrer

dor local e produção de exsudato seropurulento (Reithinger *et al.*, 2007; Anversa *et al.*, 2018; Carvalho *et al.*, 2022; OPAS, 2023).

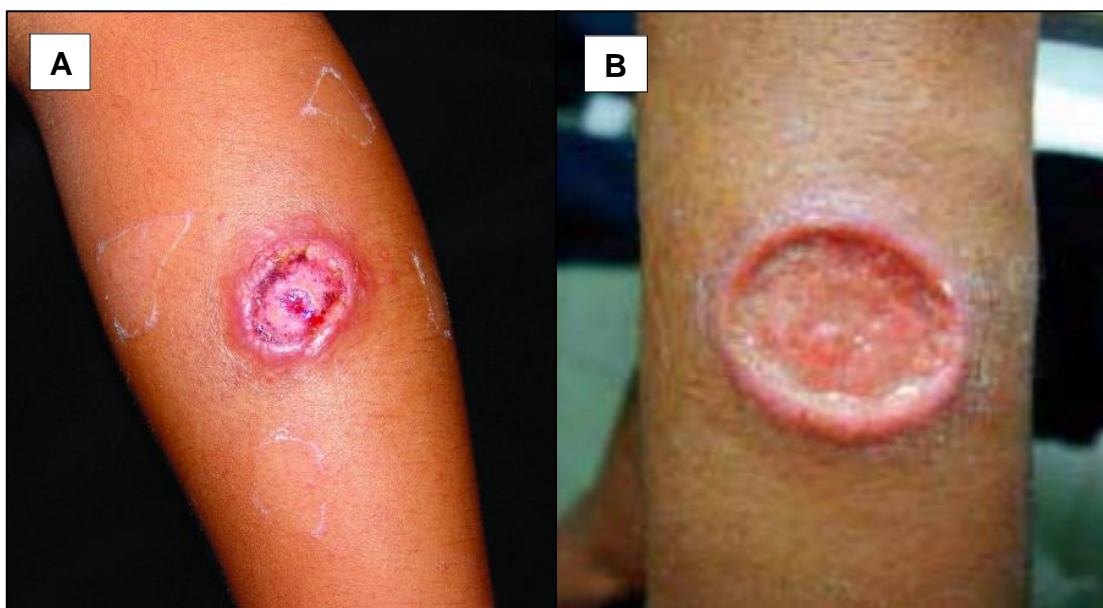


Figura 4 – Lesões ulceradas, arredondadas e com bordas bem elevadas de leishmaniose cutânea. Fonte: A - Torres-Guerrero *et al.* 2017; B – Brasil, 2017.

Ressalta-se que outros tipos de lesões, menos frequentes, também podem ser encontradas, como as vegetantes e as verrucosas que podem ser primárias ou evoluir a partir de úlceras. As vegetantes possuem aspecto papilomatoso, úmido e consistência mole. Enquanto as verrucosas apresentam superfície seca, áspera, com pequenas crostas e descamação. Ademais, ao redor da lesão principal, poderá ocorrer induração subcutânea e pápulas satélites, podendo coalescer e formar placas. Também pode apresentar linfangite nodular, com ou sem linfadenopatia regional, recoberta por pele íntegra ou eritematosa (forma esporotricóide). É possível surgir novas lesões de LC em áreas traumatizadas. Além disso, a doença pode ser classificada de acordo com a apresentação clínica: forma cutânea localizada, difusa ou disseminada (Figura 5) (Brasil, 2017; Mokni, 2019).



Figura 5 – Leishmaniose cutânea disseminada. Fonte: Mokni, 2019.

Em alguns pacientes com LC, lesões na fase inicial não melhoram no período esperado. Se a infecção durar mais de 2 anos, é considerada LC crônica, assim, elas podem persistir por vários anos e apresentar baixa carga parasitária. Por conseguinte, não ulceram e são resistentes ao tratamento (Gurel; Tekin; Uzun, 2020).

A LC é caracterizada como benigna, a qual a doença pode progredir a cura espontânea, mesmo sem tratamento, em um período de meses a poucos anos. No entanto, também pode permanecer ativa por muitos anos e coexistir com lesões de surgimento posterior, na mucosa. Frequentemente, deixam

cicatrizes atróficas (Figura 6), deprimidas, apresentando superfície lisa, áreas hipo ou hiperpigmentadas e traves fibrosas (Brasil, 2017).



Figura 6 – Cicatriz atrófica de paciente que teve leishmaniose cutânea. Fonte: Mokni, 2019.

Ainda que possa ser causada por todas as espécies dermatrópicas de *Leishmania*, algumas características particulares são atribuídas a diferentes espécies, por exemplo, as lesões causadas pela *L. (L.) amazonensis* apresentam bordas mais infiltradas, isto é, histologicamente, essas lesões têm um denso infiltrado dérmico de macrófagos vacuolados contendo bastante parasitos. Diferentemente, as lesões causadas pelas espécies do subgênero *Viannia*, apresentam o infiltrado mais discreto, predominância de linfócitos e plasmócitos, além da escassez de macrófagos e parasitos (Brasil, 2017).

Em pacientes com coinfeção *Leishmania*-HIV, lesões ulceradas são mais comuns. Entretanto, o aspecto de lesão varia de pápulas a úlceras, sendo únicas ou múltiplas, e podem se apresentar como lesões atípicas caracterizadas por máculas ou pápulas disseminadas. Nesse interim,

pacientes coinfectados com imunossupressão grave apresentam lesões em áreas expostas e não expostas, assim como na região genital (Brasil, 2017; Brasil, 2023).

O polimorfismo da LC dificulta o diagnóstico. Dessa maneira, o diagnóstico diferencial é importante, pois outras doenças dermatológicas com manifestações cutâneas semelhantes são comuns em áreas endêmicas de LC. Seguem os principais diagnósticos diferenciais: tuberculose cutânea, micobacterioses atípicas, paracoccidioidomicose cutânea, esporotricose, difteria cutânea, úlcera venosa, úlceras decorrentes da anemia falciforme, picadas de insetos, granuloma por corpo estranho, ceratoacantoma, carcinoma basocelular, carcinoma espinocelular, histiocitoma, linfoma cutâneo, cromoblastomicose, piodermites, trauma local, histoplasmose, criptococose cutânea, micobacteriose disseminada e hanseníase virchowiana (Reithinger *et al.*, 2007; Brasil, 2017; Mokni, 2019; Espanha *et al.*, 2023).

As lesões de LC podem se apresentar em localização incomum, em quantidades inesperadas ou se manifestar clinicamente com morfologias atípicas, como formas erisipelóide, esporotricóide, eczematosa, lupóide, verrucosa, paroníquia, acneiforme, anular, palmoplantar e psoriasiforme. Lesões nodulares ou noduloulcerativas podem ser confundidas com neoplasias, como carcinoma basocelular e carcinoma espinocelular. A LC também pode assemelhar-se a muitas outras condições, por exemplo, pioderma gangrenoso, lúpus vulgar, lúpus eritematoso, sarcoidose e granuloma anular (Gurel; Tekin; Uzun, 2020). Algumas dermatoses que podem ser confundidas com LC:

- A LC pode se manifestar de forma semelhante com a erisipela, uma infecção bacteriana (Figura 7) (Karincaoglu; Esrefoglu; Ozcan, 2004).




Figura 7 – Leishmaniose cutânea erisipelóide. Fonte: Gurel; Tekin; Uzun, 2020.

- Pode parecer um ectima, um furúnculo ou um carbúnculo (Samady; Schwartz, 1997).
- Pode ser semelhante ao eczema (Gurel; Ulukanligil; Ozbilge, 2002; Solomon *et al.*, 2016).
- A LC pode apresentar-se como lesões eritêmato-descamativas ou placas hiperqueratóticas, assemelhando-se a psoríase (Figura 8) (Bari; Rahman, 2008).



Figura 8 - Leishmaniose cutânea psoriasiforme. Fonte: Gurel; Tekin; Uzun, 2020.

- A forma disseminada da LC pode ser erroneamente diagnosticada como erupção acneiforme (Figura 9), rosácea granulomatosa ou outra dermatite granulomatosa (Turetz *et al.*, 2002; Moravvej, 2013).
- Pode ser confundida com esporotricose (Figura 10), infecções micobacterianas atípicas, nocardiose e doença da arranhadura do gato (Iftikhar; Bari; Ejaz, 2003; Bari, 2012; Douba, 2012; Thomaidou *et al.*, 2015; Solomon *et al.*, 2016).



Figura 9 - Leishmaniose cutânea acneiforme. Fonte: Gurel; Tekin; Uzun, 2020.



Figura 10 - Forma esporotricóide de leishmaniose cutânea. Fonte: Gurel; Tekin; Uzun, 2020.

Em pacientes com lesões sugestivas de leishmaniose, o diagnóstico deve ser baseado na conjunção dos critérios: clínico, epidemiológico e laboratorial – método complementar e, eventualmente, a prova terapêutica. Considerando a variedade de doenças que faz diagnóstico diferencial com LC, nos indivíduos em que os métodos anteriores não proporcionarem um

diagnóstico conclusivo, deverá ser realizada a investigação por meio de outros métodos diagnósticos. Salienta-se que os métodos de diagnóstico laboratorial além de confirmarem os achados clínicos, também fornecem importantes informações epidemiológicas, como a identificação da espécie de *Leishmania*, assim, orientam quanto às medidas a serem adotadas para o controle da doença (Brasil, 2017; Brasil, 2023).

O diagnóstico laboratorial deve seguir o Manual de Vigilância da Leishmaniose Tegumentar, e constitui-se fundamentalmente pelos exames parasitológico, molecular, imunológico e histopatológico (Brasil, 2017), descritos a seguir:

- **Parasitológico:**

- **Demonstração direta do parasito:** é o mais rápido, de menor custo e de fácil execução. Ocorre de acordo com os seguintes procedimentos: escarificação da borda da lesão, biópsia com impressão do fragmento cutâneo em lâmina por aposição e punção aspirativa;
- **Isolamento em cultivo *in vitro* (meios de cultivo):** permite a confirmação da presença do agente etiológico e, posteriormente, a identificação da espécie de *Leishmania* envolvida. Os fragmentos são obtidos geralmente por biópsia da borda da úlcera;
- **Isolamento *in vivo* (inoculações animais):** o material é obtido por biópsia ou raspado da lesão. Em razão da complexidade e do custo elevado, é um método pouco utilizado, apesar de apresentar alta sensibilidade entre os demais métodos parasitológicos;

- **Molecular:**

- Reação em cadeia de polimerase (PCR): baseado na amplificação do DNA do parasito em diferentes tipos de amostras, é um método considerado de alta sensibilidade e especificidade.

- **Imunológico:** intradermoreação de Montenegro (IDRM).

- **Histopatológico:** o quadro histopatológico típico é uma dermatite granulomatosa difusa ulcerada.

É recomendada a confirmação do diagnóstico por método parasitológico antes do início do tratamento, especialmente em casos com evolução clínica fora do habitual e/ou má resposta a tratamento anterior (Brasil, 2023). Para a definição de casos, a última versão do Manual do Ministério da Saúde (Brasil, 2017) admite os seguintes critérios:

- **Caso suspeito:** indivíduo com presença de lesões de pele ulceradas ou não, com três semanas ou mais de evolução em paciente residente ou exposto à área de transmissão.
- **Caso confirmado:** a confirmação dos casos clinicamente suspeitos deverá preencher no mínimo um dos seguintes critérios abaixo.
 - i. Residência, procedência ou deslocamento em/de/para área com confirmação de transmissão e encontro do parasito nos exames parasitológicos diretos e/ou indireto;
 - ii. Residência, procedência ou deslocamento em/de/para área com confirmação de transmissão e IDRМ positiva;
 - iii. Residência, procedência ou deslocamento em/de/para área com confirmação de transmissão com outros métodos de diagnóstico positivo;
- **Caso descartado:** Caso suspeito com diagnóstico laboratorial negativo ou caso suspeito com diagnóstico confirmado de outra doença.

1.2 Inteligência artificial

Ao longo da história, a inteligência artificial (IA) evoluiu de um conceito abstrato, criado por escritores de ficção e filósofos visionários, como René Descartes, que usou a metáfora do “homem mecânico” para descrever a possibilidade de máquinas dotadas de inteligência. Isso mostra que embora a IA seja ancorada à ciência da computação, ela está enraizada em outras

ciências, como na filosofia, biologia, matemática, metafísica e sociologia (Pk, 1984; Abbass, 2021).

À medida que o tempo avançou, a ascensão da Revolução Industrial catalisou um significativo desenvolvimento das tecnologias, de tal modo que muitos trabalhos manuais foram substituídos ou melhorados, proporcionando benefícios notáveis à humanidade (Pk, 1984). Os primeiros estudos sobre a operação da mente contribuíram para estabelecer o pensamento lógico contemporâneo acerca dos programas e computadores. Em 1950, Alan Turing, um dos pioneiros da computação moderna e da IA, publicou o artigo "Computing Machinery and Intelligence", que descreve a criação e o teste de máquinas inteligentes, chamado de teste de Turing (Figura 11). No teste, a máquina é considerada inteligente se um humano não conseguir distinguir entre uma máquina e outro humano ao interagir com ambos. Assim, se tornou o modelo teórico fundamental para o processamento de informações. Posteriormente, em 1956, o termo "inteligência artificial" foi usado por John McCarthy durante a conferência de Dartmouth, marcando o início formal da IA (Ramesh *et al.*, 2004; Qashqai; Vahedi; Al-Haddad, 2019; Nensa; Demircioglu; Rischpler, 2019).

Atualmente, ainda é difícil definir com exatidão o que é a IA. No entanto, é caracterizada pela capacidade de uma máquina comunicar-se, raciocinar e operar de maneira independente e semelhante a um ser humano. Inclui também a capacidade de aprender com experiências passadas, compreender e processar linguagem natural (Du-Harpur *et al.*, 2020). Além da IA ser complexa, está em constante desenvolvimento, moldando nosso futuro com tecnologias cada vez mais sofisticadas e inteligentes.

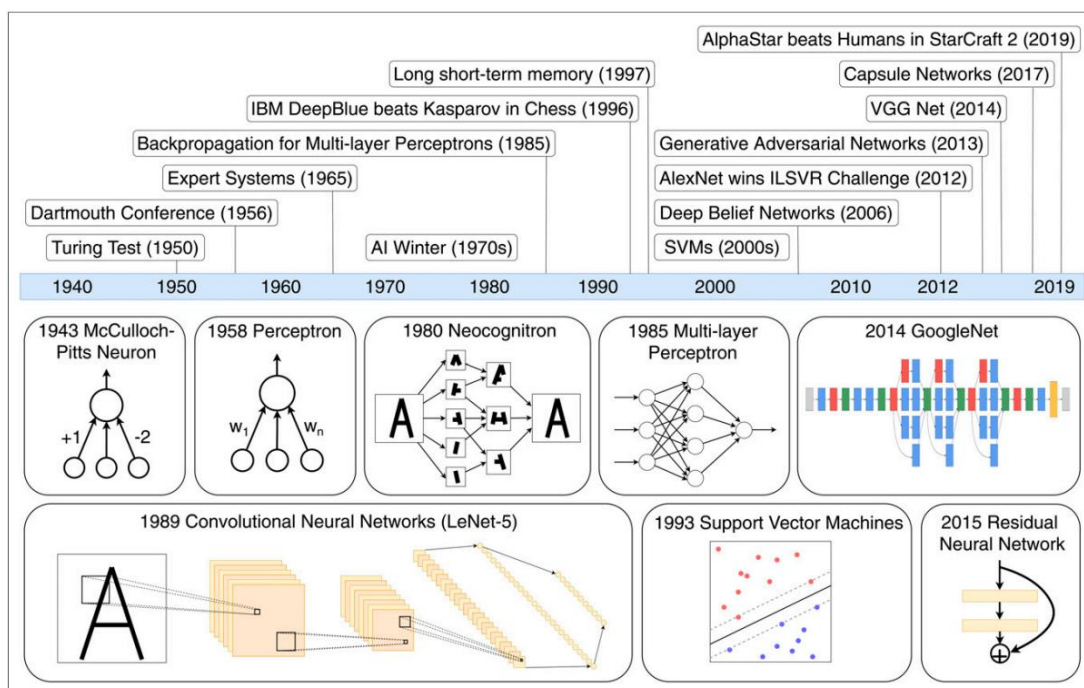


Figura 11 – Linha do tempo de momentos importantes no desenvolvimento da Inteligência Artificial. Fonte: Nensa; Demircioglu; Rischpler, 2019.

1.2.1 Aprendizado de máquina

O reconhecimento de padrões é uma das áreas mais populares da IA. O cérebro humano pode analisar grandes quantidades de dados para encontrar padrões específicos. Baseado nisso, o mesmo método é implementado em máquinas, sendo denominado de "aprendizado de máquina" (ML – *Machine Learning*). Entretanto, as máquinas demonstram-se mais eficazes nessa função, devido à sua capacidade de resposta rápida, estruturas de dados multidimensionais, processamento paralelo e extenso armazenamento de dados. De modo geral, algoritmos e modelos estatísticos podem aprender conjuntos de dados mais complexos com centenas de dimensões, capazes de reconhecer e inferir padrões (Figura 12) e fazer previsões (Qashqai; Vahedi; Al-Haddad, 2019; Du-Harpur *et al.*, 2020).

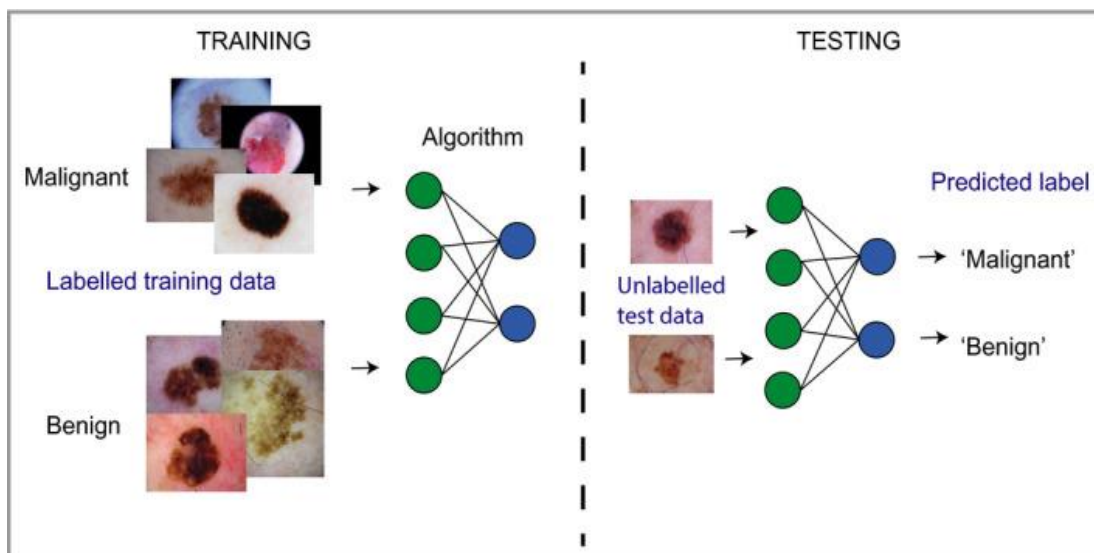


Figura 12 – Esquema ilustrando como um algoritmo de aprendizado de máquina treina em um grande conjunto de dados, associando dados a rótulo (aprendizado supervisionado). Fonte: Du-Harpur *et al.*, 2020.

Inicialmente, os algoritmos de ML foram projetados e usados para analisar conjuntos de dados médicos e, atualmente, fornecem diversas ferramentas indispensáveis para análise inteligente de dados (Kononenko, 2001). Para treinar a máquina usando dados existentes, podem ser consideradas diferentes abordagens, pois existem três tipos de algoritmos de ML: i) supervisionado: algoritmo treinado com dados que também contêm a resposta (Figura 12); ii) não supervisionado: algoritmo treinado com dados no qual a máquina deve encontrar o padrão por conta própria; iii) por esforço: algoritmo que recebe um objetivo e executa séries suficientes de tentativas e erros para atingi-lo (Qashqai; Vahedi; Al-Haddad, 2019; Janiesch; Zschech; Heinrich, 2021).

Durante o processo de extração de padrões, o ML analisa os recursos de imagem considerados importantes para a previsão ou diagnóstico desejado (Erickson *et al.*, 2017). Além disso, está representado por métodos, técnicas e ferramentas que podem auxiliar no diagnóstico e prognóstico de uma diversidade de domínios médicos, como na previsão da progressão de doenças, na aplicação do conhecimento médico para a avaliação de resultados, no planejamento e suporte de terapias para o gerenciamento de pacientes (Magoulas; Prentza, 2021).

Apesar do termo “aprendizado de máquina” ser relativamente recente, tem sido utilizado em imagens médicas há décadas, especialmente nas áreas de diagnóstico auxiliado por computador e mapeamento cerebral funcional (Wernick *et al.*, 2010). Nesse interim, sua utilidade se estende para a análise de dados, incluindo a detecção de regularidades em conjuntos de dados imperfeitos, a interpretação de dados contínuos utilizados em Unidade de Terapia Intensiva (UTI) e a geração de alertas inteligentes para monitoramento eficaz e eficiente. Dessa maneira, a correta implementação dos métodos pode ajudar a integralizar sistemas computacionais em ambientes de saúde, proporcionando oportunidades de facilitar e aprimorar o trabalho de médicos especialistas, bem como de melhorar a eficiência e qualidade do atendimento médico (Magoulas; Prentza, 2021).

1.2.2 Aprendizagem profunda e Redes Neurais

Nas últimas décadas, o aprendizado profundo (DL – *Deep Learning*) revolucionou o cenário do ML. Ademais, é considerado um subconjunto mais sofisticado do ML, no qual refere-se a uma rede neural com múltiplas camadas de ‘neurônios’ e possui pesos ajustáveis, isto é, está relacionado a algoritmos de redes neurais artificiais (ANN’s – *Artificial Neural Networks*) que aprendem com grandes bancos de dados (Qashqai; Vahedi; Al-Haddad, 2019; Du-Harpur *et al.*, 2020).

Nos últimos anos, o DL consolidou-se como a abordagem computacional mais utilizada no campo do ML. De maneira geral, os estudos de DL envolvem três tipos de conjuntos de dados: treinamento, validação e teste. O conjunto de dados de treinamento desempenha o papel na formação de modelos DL, nos quais os algoritmos são ajustados para executar funções específicas. O conjunto de dados de validação é usado para avaliar o desempenho do modelo, ao mesmo tempo que ajusta sua arquitetura. Por fim, o conjunto de dados de teste fornece a avaliação final do modelo (Choy *et al.*, 2023).

Os modelos de DL operam convertendo dados de entrada (por exemplo, imagens) em saídas correspondentes (por exemplo, doença presente/ausente), ao mesmo tempo que aprimoram a compreensão de características em nível cada vez mais alto (Litjens *et al.*, 2017). As técnicas de DL têm sido implementadas em diversas áreas, por exemplo, no reconhecimento de fala, de padrões e bioinformática. Nos últimos anos, várias abordagens têm sido implementadas na detecção precoce de câncer de pele (Dildar *et al.*, 2021). Nesse sentido, em imagens médicas, a classificação é a principal tarefa do DL, com a finalidade de investigar questões relacionadas à clínica para o tratamento precoce do paciente. Essa tarefa pode ocorrer de forma clássica ou com múltiplas imagens como entrada, resultando em um único diagnóstico. Nessas situações, cada teste diagnóstico é um modelo e os tamanhos dos conjuntos de dados apresentam características menores quando comparados com os de visão computacional (Latif *et al.*, 2019).

Os modelos de DL podem resolver problemas críticos identificando automaticamente os recursos de dados de entrada, e são adaptáveis à mudança no problema considerado. Essas técnicas adquirem os dados inferidos para identificar e explorar as características nos padrões de dados não expostos com modelos computacionais ainda baixos, resultando em eficiência considerável (Srinivasu *et al.*, 2021).

DL tem conquistado notáveis avanços na resolução de problemas que desafiaram a comunidade de inteligência artificial por muitos anos. É evidente sua eficácia na identificação de estruturas intrincadas em grandes bancos de imagens. A técnica se revela como ferramenta promissora para o processamento de imagens e para sinais vitais, como eletrocardiograma, eletroencefalograma e fonocardiograma (Souza *et al.*, 2019).

O melhor tipo de modelo de DL para análise de imagens são as redes neurais convolucionais (CNN's – *Convolutional Neural Networks*). As CNN's são compostas por várias camadas que aplicam filtros de convolução para características específicas dentro de uma imagem (Latif *et al.*, 2019; Du-Harpur *et al.*, 2020).

Em redes neurais, as informações são passadas através de uma série de pontos interconectados, semelhante aos neurônios biológicos (Figura 13). Cada ponto de conexão funciona como uma operação matemática (por exemplo, adição, multiplicação). Um conjunto desses pontos interconectados dentro da rede forma uma "camada", e a estrutura geral dessas camadas é chamada de "arquitetura". Durante o treinamento, cada ponto é ajustado e otimizado através de um processo iterativo chamado "*backpropagation*", permitindo que a rede neural aprimore sua precisão de classificação (Du-Harpur *et al.*, 2020).

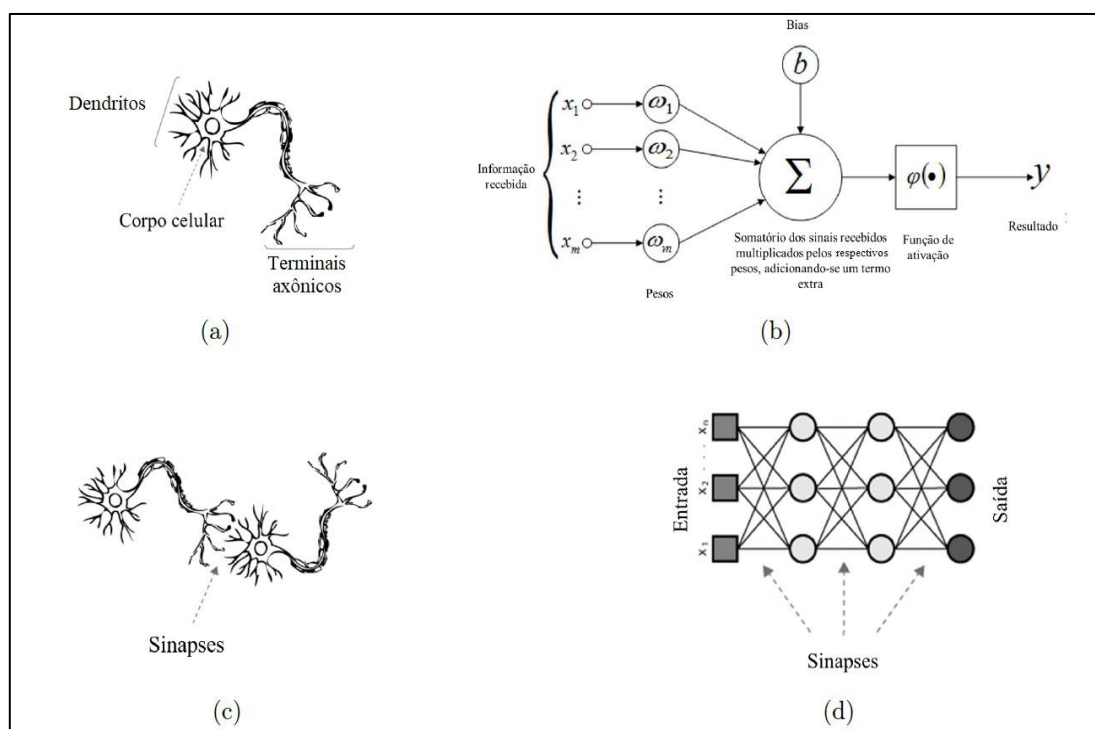


Figura 13 – Comparação entre neurônios biológicos e redes neurais artificiais. (a) estrutura de um neurônio biológico; (b) estrutura de um neurônio artificial; (c) e (d) ilustram as redes biológica e artificial, respectivamente. Fonte: Adaptado de Gonçalves, 2019.

Em CNN's, as camadas contêm filtros (Figura 14) que operam sob a ideia de que a localização de uma característica em uma imagem é muito menos importante do que se essa característica está presente ou não. Um filtro convolucional aprende uma característica específica da imagem, independentemente de onde ela ocorre na imagem (quadros na figura 14). A rede compreende diversos filtros hierárquicos que aprendem representações

abstratas da imagem. Em princípio, esses filtros têm a capacidade de aprender características dermoscópicas semelhantes às identificadas pelos clínicos. No entanto, na prática, as características reconhecidas podem variar dos critérios diagnósticos clássicos (Du-Harpur *et al.*, 2020).




Figura 14 – Representação esquemática de como as tarefas de classificação de imagens são realizadas em redes neurais convolucionais. Fonte: Du-Harpur *et al.*, 2020.

A popularidade das CNN's como um método para classificação de imagens aumentou após o desenvolvimento da CNN AlexNet em 2012. Atualmente, o emprego das CNN's em atividades de classificação disparou devido à sua comprovada e consistente eficácia. Nesse sentido, novas arquiteturas de CNN's foram desenvolvidas, refinadas e disponibilizadas ao público por instituições com alto nível de especialização e recursos computacionais (Du-Harpur *et al.*, 2020).

1.3 Avanços da inteligência artificial na medicina

A aplicação da IA na medicina tem sido bastante observada na análise de imagens médicas, destacando-se como uma das primeiras áreas a receber contribuições significativas através do diagnóstico por imagem, auxiliando na interpretação e identificação de anomalias em radiografias, ressonâncias magnéticas e tomografias computadorizadas. Além da identificação e

classificação de imagens, seu emprego já se estende a muitas outras áreas da medicina, tais como: (i) testes genéticos, realizando análise genômica; (ii) triagem de pacientes, proporcionando diagnósticos preliminares a partir de dados clínicos e históricos; (iii) desenvolvimento de fármacos, otimizando a identificação de compostos promissores; (iv) assistência virtual, dando suporte e fornecendo informações; (v) gerenciamento de dados de pacientes com a finalidade de identificar padrões e, assim, melhorar a eficiência e o atendimento; (vi) procedimentos cirúrgicos assistidos por sistemas robóticos. Assim, a IA está sendo aplicada nos principais campos dos serviços de saúde: detecção e diagnóstico precoce, tratamento, predição de resultados e avaliação de prognóstico (Jiang *et al.*, 2017; Hamet; Tremblay, 2017; Kaul; Enslin; Gross, 2020; Jiménez-Luna *et al.*, 2021; Akazawa; Hashimoto, 2021; Liu *et al.*, 2021; Haug; Drazen, 2023).

O DL foi utilizado em imagens médicas para a classificação da massa mamária, na segmentação de lesões no cérebro, detecção de vazamento em segmentação de árvore brônquica, classificação de retinopatia diabética, segmentação de próstata, classificação de nódulos, detecção de metástases de câncer de mama e supressão óssea. A IA também foi aplicada na classificação de pacientes tendo doença de Alzheimer com base na ressonância magnética cerebral, além de ter sido aplicada em imagens de patologia digital e tomografia pulmonar computadorizada. A aplicação da IA aumenta o nível de diagnóstico por meio da ultrassonografia, por exemplo, na detecção de tumores na tireoide, mama, brônquios, músculo pubo retal, hiato urogenital, bem como outras lesões obstétricas e ginecológicas (Litjens *et al.*, 2017; Liu *et al.*, 2021).

Além da identificação de imagens, a IA e o ML entraram na medicina de várias maneiras (Figura 15), ajudando a identificar surtos de doenças infecciosas que podem impactar na saúde pública; uso de múltiplas fontes de informação (resultados clínicos, genéticos e laboratoriais) sobre um paciente para fazer um diagnóstico e identificar condições raras e comuns que poderiam ter escapado da detecção; apoio no desempenho de ensaios clínicos, identificando, recrutando e preservando os pacientes; auxílio na

organização operacional hospitalar, como agendamento de sala para cirurgias; acompanhamento de pacientes; faturamento e cobranças (Haug; Drazen, 2023).

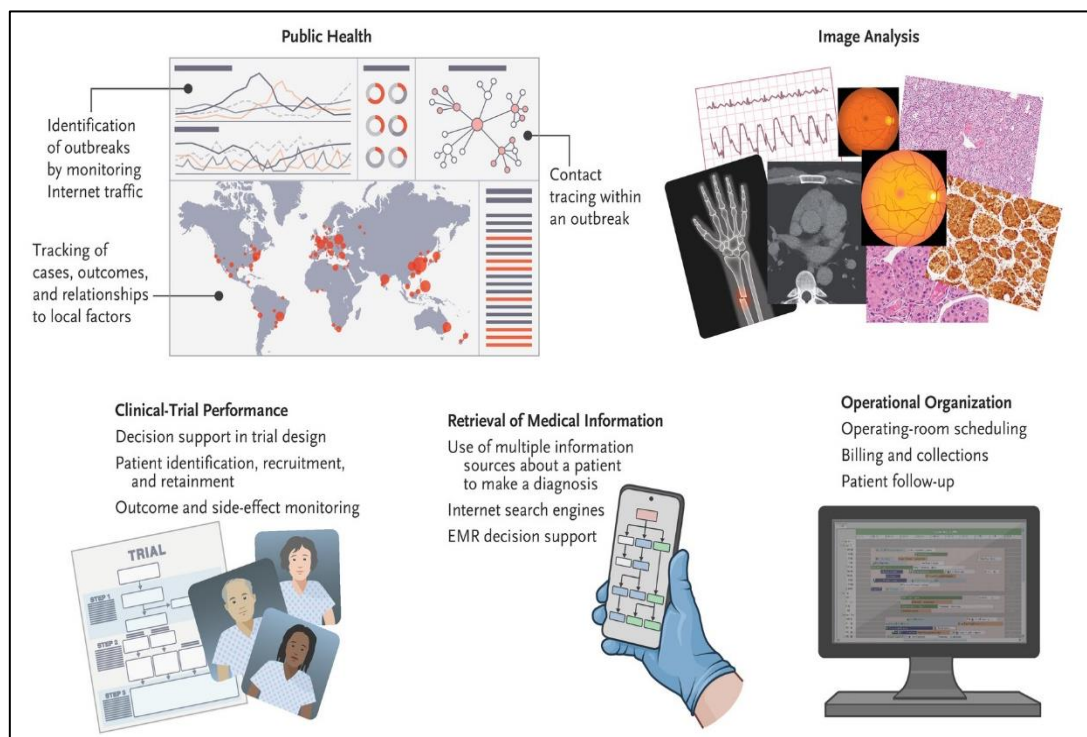


Figura 15 – Aplicações da inteligência artificial na medicina. Fonte: Adaptado de Haug; Drazen, 2023.

Embora, a literatura da IA esteja cada vez mais rica na área da saúde, os estudos concentram-se principalmente em alguns tipos de doenças: câncer, doenças do sistema nervoso e doenças cardiovasculares (Jiang *et al.*, 2017). No entanto, a IA tem impactado uma variedade de agravos, como diabetes, doenças respiratórias (exemplo, tuberculose e COVID-19), doenças parasitárias (exemplo, detecção de parasitos como *Plasmodium* – Malária, *Leishmania* – Leishmanioses, *Trypanosoma* – doença de Chagas e seus vetores). Nesse último caso, estudos têm aplicado algoritmos de IA na identificação de espécies de triatomíneos brasileiros e mexicanos. Recentemente, um estudo demonstrou que imagens fotografadas com celular em diferentes posições foram identificadas com uma acurácia de aproximadamente 99%, especialmente na identificação dos principais

gêneros de triatomíneos. Esse avanço representa um passo significativo para o desenvolvimento de um aplicativo baseado em IA para a identificação de barbeiros. Ademais, a IA analisa os genes e características clínicas relacionadas, aplicação que facilita o diagnóstico da síndrome de Noonan, uma desordem autossômica comum, principalmente em pacientes atípicos. Além da utilização do sequenciamento profundo para analisar genes que são frequentemente mutados na leucemia mieloide aguda, contribuindo para a detecção e monitoramento mais precoces (Becker *et al.*, 2017; Gurgel-Gonçalves *et al.*, 2017; Rajaraman *et al.*, 2018; Souza *et al.*, 2019; Khalighifar *et al.*, 2017; Li *et al.*, 2020; Sanchez-Patiño *et al.*, 2021; Liu *et al.*, 2021; Morais *et al.*, 2022; Ojeda-Pat *et al.*, 2022; Miranda *et al.*, 2024).

Na gastroenterologia, a IA tem sido utilizada através da realização de diagnóstico assistido por computador aplicado à colonoscopia para melhorar a detecção e diferenciação entre pólipos benignos e malignos do cólon; na diferenciação de pancreatite crônica do câncer de pâncreas; no prognóstico de sobrevida no adenocarcinoma de esôfago, com o intuito de prever recidiva e gravidade da doença inflamatória intestinal, e informar a probabilidade de metástases à distância no carcinoma epidermóide de esôfago; na detecção de anomalias endoscópicas de cápsulas do intestino delgado e câncer gástrico (Kaul; Enslin; Gross, 2020).

Nos últimos anos, o desenvolvimento da IA promoveu uma significativa transformação na indústria tradicional de medicamentos na área da saúde, facilitando a descoberta e o desenvolvimento de novos medicamentos. Além disso, a pesquisa de ferramentas e métodos bioinformáticos assistidos por IA também proporciona um futuro promissor para a terapia medicamentosa com moléculas pequenas, biomarcadores gênicos e identificação de novos alvos de drogas para várias doenças (Liu *et al.*, 2021; Nayariseri *et al.*, 2021). As aplicações da IA também se estendem a anestesiologia: (i) profundidade da monitorização anestésica, (ii) controle da anestesia, (iii) predição de eventos e riscos, (iv) orientação ultrassonográfica, (v) controle da dor e (vi) logística da sala de cirurgia (Hashimoto *et al.*, 2020).

Quanto aos avanços da IA nas leishmanioses, estudos empregaram IA na identificação de novos compostos químicos com potencial atividade antileishmania (Castillo-Garit *et al.*, 2018; Herrera-Acevedo *et al.*, 2021; Scotti *et al.*, 2022). A IA tem sido utilizada na detecção de *Leishmania* em imagens microscópicas com um sistema baseado em ML (Zare *et al.*, 2022). Além disso, está presente em estudos de diagnóstico de leishmaniose visceral baseado em algoritmos de ML, alcançando uma boa acurácia geral e em avaliação de carga parasitária a partir de dados clínicos (teste sorológico, marcadores bioquímicos e sinais físicos) de cães com leishmaniose (Torrecilha *et al.*, 2017; Larios *et al.*, 2021).

1.3.1 Inteligência artificial na dermatologia

A IA possui ampla aplicação em saúde e está se tornando cada vez mais importante na dermatologia, com estudos relatando acurácia compatível aos dermatologistas no diagnóstico de lesões de pele a partir de imagens clínicas e dermatoscópicas. Assim, métodos de DL têm mostrado grande potencial para detecção e identificação de lesões cutâneas de muitas dermatoses (Young *et al.*, 2020; Kulkarni *et al.*, 2020; Li *et al.*, 2023).

Inicialmente, as pesquisas de IA em dermatologia se concentraram no câncer de pele, existindo uma grande quantidade de estudos, especialmente para identificação de melanoma. Uma meta-análise de 70 estudos demonstrou que o desempenho do diagnóstico de melanoma, quando auxiliado por computador, é comparável à de especialistas humanos. Esse desempenho foi alcançado utilizando CNN's em imagens dermatoscópicas e não dermatoscópicas. Além disso, estudos relataram que as CNN's superaram os dermatologistas na classificação de imagens de cinco classes de doenças: (i) ceratose actínica, carcinoma intraepitelial (doença de Bowen), carcinoma espinocelular; (ii) carcinoma basocelular; (iii) ceratose benigna, ceratose seborreica, lentigo solar e líquen plano; (iv) nevo melanocítico e (v) melanoma. Em outro estudo, quando a CNN foi treinada com um conjunto de 129.450 imagens, ela alcançou um desempenho comparável ao de

dermatologistas em duas tarefas de classificação: diferenciar entre carcinoma e queratoses seborreicas, e melanomas de nevos (Esteva *et al.*, 2017; Dick *et al.*, 2019; Maron *et al.*, 2019; Young *et al.*, 2020).

As CNN's também têm sido utilizadas para classificar imagens clínicas de outras doenças de pele. Nesse sentido, Han *et al.* (2018) testaram um algoritmo de DL em 12 doenças de pele, como granuloma piogênico, hemangioma, dermatofibroma verruga, além de cânceres de pele e ceratoses. Choy *et al.* (2023) realizaram uma revisão sistemática que mostrou as doenças que estão sendo mais estudadas na análise de imagens para o diagnóstico com DL: acne, psoríase, eczema, rosácea, vitiligo e urticária. Nesse estudo, os algoritmos de DL apresentaram alta especificidade e sensibilidade no diagnóstico dessas condições. Li *et al.* (2023) realizaram um estudo de IA para a identificação de oito tipos de lesões de pele: melanoma, nevo melanocítico, carcinoma basocelular, ceratose actínica, ceratose benigna, dermatofibroma, lesão vascular, carcinoma espinocelular. Os resultados demonstram o potencial na identificação dessas doenças. Além disso, Baweja e Parhar (2016) realizaram um estudo com CNN para a identificação de lesões de hanseníase, o qual teve um excelente resultado e, mais recentemente, Thieme *et al.* (2023) realizaram um estudo de detecção precoce de lesões cutâneas causadas pelo MPXV através de imagens, apresentando alta sensibilidade e especificidade, demonstrando que o DL tem potencial para ajudar na mitigação de surtos de MPXV.

Diante do exposto, a IA tem grande potencial de benefício para a dermatologia, nas análises de imagens de lesões de pele – o que pode ser um passo importante para diagnóstico preciso, melhorando a qualidade dos cuidados dermatológicos. A IA pode revolucionar o atendimento ao paciente, particularmente na melhoria da acurácia e sensibilidade do rastreamento de lesões de pele (De *et al.*, 2020).

1.3.2 Inteligência artificial e leishmaniose cutânea

Os avanços da IA revolucionaram a dermatologia. No entanto, há poucos estudos aplicando ML para diagnosticar dermatoses causadas por agentes infecciosos, como espécies de *Leishmania*. Bamorovat *et al.* (2021) apresentaram um novo método de diagnóstico e prognóstico para classificar LC, incluindo pacientes responsivos e não responsivos, mostrando o potencial de identificação automática de LC usando técnicas de ML. Steyve *et al.* (2022) apresentam uma abordagem diagnóstica otimizada para doenças tropicais negligenciadas (DTN's) de pele (LC, hanseníase e úlcera de Buruli), identificando automaticamente as lesões cutâneas em sua fase inicial. Além disso, Noureldeen *et al.* (2023) mostraram um método de classificação e diagnóstico, estabelecendo um modelo de treinamento para reconhecer a LC em condições normais, baseado na rede YOLOv5 uma abordagem de DL.

Um novo passo nessa área é analisar imagens de LC em comparação com outras doenças de pele causadas por infecções fúngicas, bacterianas, e doenças não infecciosas, aplicando redes neurais pré-treinadas, como AlexNet, para auxiliar no diagnóstico de LC.

2 JUSTIFICATIVA

Muitas DTN's se manifestam como lesões na pele e são importantes problemas de saúde pública. Um exemplo é a LC, uma doença infecciosa, parasitária, não contagiosa que afeta cerca de 1 milhão de indivíduos em todo o mundo, principalmente em regiões tropicais e subtropicais. As lesões cutâneas resultantes de LC podem se apresentar de diversas maneiras, podendo ser únicas, múltiplas, disseminadas ou difusas. Essas lesões podem impactar negativamente na qualidade de vida dos indivíduos afetados, especialmente em casos mais graves, nos quais há comprometimento das mucosas do nariz e orofaringe. Nesses casos, os sintomas podem incluir sangramento, coriza, dificuldade na deglutição e fala. Além disso, pode trazer alterações funcionais e estéticas com lesões desfigurantes, principalmente na face, afetando significativamente sua aparência, a saúde mental e social, contribuindo para a estigmatização dos indivíduos afetados. Dessa forma, a LC não compromete apenas a saúde física, mas também interfere na integridade emocional e na interação social dos indivíduos.

O diagnóstico mais precoce dessa doença pode melhorar o acesso do paciente aos cuidados de saúde, permitindo também o tratamento em tempo adequado. Entretanto, o diagnóstico da LC depende da experiência de profissionais de saúde, como dermatologistas e infectologistas com prática em doenças tropicais, e de procedimentos laboratoriais, tornando o processo de diagnóstico lento e, muitas vezes, tardio. Além disso, pouco se tem investido em ferramentas de diagnóstico e estratégias de gestão para o controle da LC.

Os recentes avanços da IA com algoritmos de DL podem transformar a forma de identificação das lesões de LC. Esses modelos têm a capacidade de analisar e identificar grandes bancos de imagens, extraindo padrões complexos e desempenhando um papel importante no auxílio ao diagnóstico. Assim, a rápida e acurada identificação de lesões de LC é fundamental para reduzir os impactos da doença. Diante disso, a aplicação da IA na LC torna-se uma ferramenta promissora para auxiliar o processo de diagnóstico,

reduzindo o tempo para a obtenção de resultados e permitindo o tratamento mais rápido.

Há poucos estudos aplicando ML para diagnosticar dermatoses causadas por agentes infecciosos, como *Leishmania*. Desse modo, essa dissertação apresenta uma abordagem inovadora e promissora na dermatologia tropical com a incorporação de um algoritmo de DL na identificação de imagens de lesões de pele causadas por LC. Essa pesquisa busca não apenas avançar no conhecimento científico, mas beneficiar os indivíduos afetados pela contribuição eficaz na saúde pública, com um método que pode melhorar o diagnóstico e, conseqüentemente, o tratamento e controle da doença, além de explorar a aplicação de tecnologias no campo da dermatologia e das DTN's.

3 OBJETIVOS

3.1 Geral

Avaliar o desempenho do algoritmo de aprendizagem profunda AlexNet para identificar imagens de lesões de LC em pacientes do Hospital Universitário de Brasília (HUB).

3.2 Específicos

- Construir um banco de imagens de pacientes atendidos no HUB representativo de LC e de outras doenças de pele.
- Organizar o banco de imagens de acordo com os dados dos prontuários dos pacientes e diagnósticos obtidos.
- Implementar (treinar e testar) o algoritmo AlexNet utilizando o banco de imagens.
- Avaliar o desempenho do algoritmo AlexNet para a identificação de imagens de LC *versus* outras doenças dermatológicas, utilizando as métricas: acurácia, sensibilidade e especificidade.

4 MATERIAIS E MÉTODOS

4.1 Desenho do Estudo e Banco de Imagens

Foram obtidas imagens de lesões cutâneas de pacientes atendidos no Ambulatório de Dermatologia do HUB, serviço de referência para diagnóstico e tratamento de leishmanioses na região centro-oeste do Brasil, no período de 2015 a 2022. Na primeira consulta, os pacientes que apresentavam lesões cutâneas foram examinados, as lesões cutâneas foram fotografadas (até 10 imagens de cada paciente) com câmera Sony alfa 7 R III-ICLÉ-R7M2 (Sony Corp, Tóquio, Japão) e lentes Sony FE 24–105mm ou F4 G OSS ou Sony FE 35mm f/2.8 (Sony Corp, Tóquio, Japão) e, em seguida, biópsias de pele e esfregaço mucocutâneo foram realizados para confirmar o diagnóstico (Gomes *et al.*, 2014; Pinheiro *et al.*, 2020; Barroso *et al.*, 2022).

Os pacientes foram classificados de acordo com o padrão de referência composto baseado na classificação operacional do HUB. Após avaliação clínica pelo dermatologista, as lesões foram submetidas a exames complementares para confirmação da LC e outros diagnósticos diferenciais. O diagnóstico de LC foi confirmado após a observação de sintomas clínicos compatíveis, com dois testes não parasitológicos positivos (imunofluorescência indireta, IDRM) ou um teste parasitológico positivo (qPCR, cultura, histopatologia ou esfregaço com amastigotas) (Figura 16). Além disso, pacientes com resultados negativos nos exames e com melhora após tratamento específico para LC também foram considerados como diagnóstico positivo para LC. A cor (eritematosa, hipo ou hiperpigmentada), a localização da lesão (membros superiores, membros inferiores, face ou tronco), o diâmetro e o tipo de lesões (mácula, pápula, placa, nódulo, úlcera, vesícula ou bolha) foram registrados. Logo, o diagnóstico final só foi estabelecido após os resultados laboratoriais estarem disponíveis e permitirem que o dermatologista comunicasse o diagnóstico e iniciasse o tratamento.

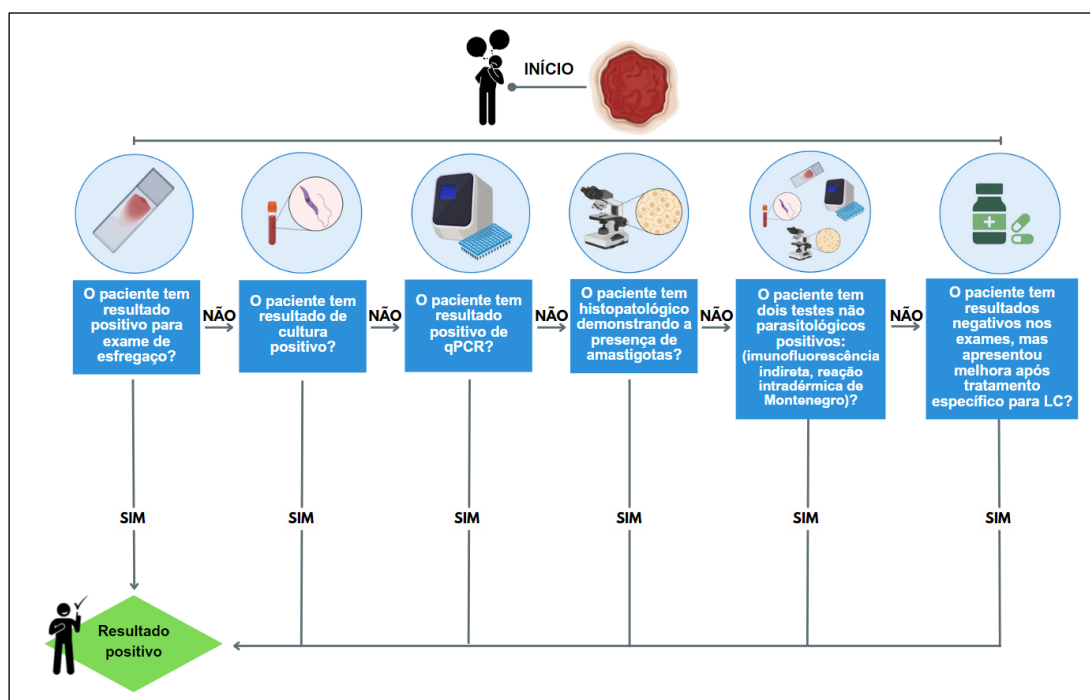


Figura 16 - Fluxo de diagnóstico de pacientes com LC atendidos no Ambulatório de Dermatologia do HUB. Fonte: Elaborado pelo autor (2024).

Foram incluídos todos os pacientes com lesões que tivessem diagnóstico conclusivo de LC. O polimorfismo da LC faz com que o diagnóstico diferencial com outras doenças seja sempre considerado. Dessa maneira, pacientes diagnosticados com outros tipos de dermatoses também foram incluídos nesse estudo (Tabela 1). Foram excluídos pacientes com lesões cutâneas localizadas em mucosas, áreas íntimas do corpo e couro cabeludo, este último devido à dificuldade de realizar fotografia de qualidade sem tricotomia. Os pacientes que não completaram a avaliação diagnóstica também foram excluídos.

Tabela 1 - Número de imagens de lesões cutâneas relacionados ao grupo de classificação, segundo a etiologia.

Grupo	Doença	n
Protozoose	Leishmaniose cutânea	1.787
Bacterioses	Ectima	55
	Erisipela	24
	Hanseníase	57
	Impetigo	26
	Piodermite	98
	Sífilis terciária	12
	Subtotal	272
Fúngicas	Cromomicose	56
	Esporotricose	22
	Líquen plano	18
	Líquen simples crônico	12
	Paracoccidioidomicose	7
	Tínea corporis	18
	Subtotal	133
Não infecciosas	Carcinoma basocelular (CBC)	31
	Carcinoma espinocelular (CEC)	40
	Ceratose actínica	8
	Dermatite	12
	Eczema	15
	Eritema pigmentar fixo	5
	Insuficiência venosa	98
	Linfocitoma cútis	8
	Linfoma	9
	Lúpus eritematoso discoide	16
	Poroceratose	7
	Psoríase	2
	Rosácea	3
	Vasculite livedóide	12
Subtotal	266	
Total geral		2.458

Em relação ao fluxo da pesquisa (Figura 17), foram obtidas até 10 imagens de cada lesão do paciente: panorâmica, *close-up*, lateral e bordas. Em seguida, foram identificadas com um código alfanumérico e salvas em disco criptografado para proteger a identidade dos participantes. Assim, foi criado um banco de imagens com pastas separadas para cada tipo de lesão cutânea. As imagens foram redimensionadas para melhorar a qualidade visual, visando remover áreas indesejadas e destacar a região de interesse (lesão). As imagens das lesões faciais também foram redimensionadas para evitar a identificação do paciente. Dessa maneira, compilamos um banco de

dados contendo 1.787 imagens de LC e 671 de outras dermatoses (Tabela 1), resultando em um total de 2.458 imagens de alta resolução utilizadas para treinar e testar o algoritmo AlexNet (Figura 17).




Figura 17 - Fluxo de execução resumindo a metodologia adotada. (A) Fotografias das lesões cutâneas dos pacientes; (B) Classificação em pastas, redimensionamento de imagens e simulações; (C) Análise do desempenho do algoritmo. Fonte: Elaborado pelo autor (2024).

4.2 Algoritmo: treino e teste

Utilizou-se um algoritmo de DL (AlexNet) para identificar as imagens das lesões cutâneas. AlexNet é uma CNN que tem 60 milhões de parâmetros e 650.000 neurônios. A rede foi pré-treinada a partir de uma base de dados formada por 1,2 milhão de imagens de alta resolução distribuídas em 1.000 classes diferentes (exemplo: objetos, animais, plantas) do banco de dados ImageNet (Krizhevsky; Sutskever; Hinton, 2012). O AlexNet tem sido utilizado com sucesso para identificação automatizada de insetos vetores (Motta *et al.*, 2019; Miranda *et al.*, 2024) e diagnóstico de doenças baseado em imagens (Hamida *et al.*, 2021; Kumar *et al.*, 2022).

O AlexNet opera de acordo com alguns componentes e princípios fundamentais: (1) possui cinco camadas convolucionais (Figura 18), responsáveis por extrair características relevantes das imagens de entrada,

que detectam padrões específicos, como bordas, texturas e formas; (2) possui camadas de *max pooling*, isto é, agrupamento máximo, que reduzem a dimensionalidade da representação da imagem de entrada, preservando características significativas e reduzindo o processamento computacional; (3) utiliza a função ReLU (Rectified Linear Unit) nas camadas convolucionais para adicionar não-linearidade à rede, permitindo aprender mais complexidades nos dados; (4) utiliza a técnica de Normalização de Resposta Local para normalizar as saídas das camadas convolucionais, promovendo competição entre neurônios (detectam padrões) das camadas convolutivas e aumentando a capacidade de generalização; (5) além das camadas convolucionais e de agrupamento máximo, possui três camadas totalmente conectadas que combinam as características aprendidas para realizar a classificação final; (6) emprega a técnica de *Dropout* (Figura 19) para combater o sobreajuste (*overfitting*), desativando aleatoriamente alguns neurônios durante o treinamento, evitando que a rede se torne muito dependente de alguns neurônios; e (7) utiliza a função *Softmax* para converter as saídas da rede em probabilidades para que a maior seja escolhida como predição final (Krizhevsky; Sutskever; Hinton, 2012).

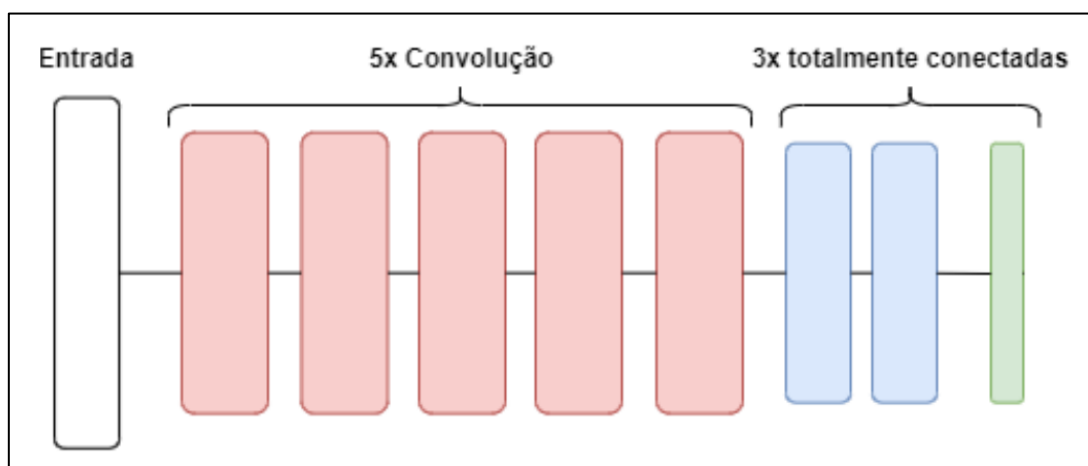


Figura 18 – Arquitetura do AlexNet. Fonte: Braga, 2021.




Figura 19 – Esquema usual de uma rede neural convolucional à esquerda. Esquema com *dropout* à direita, contendo alguns neurônios inativos. Fonte: Braga, 2021.

Quanto ao aprendizado da rede, as imagens originais foram redimensionadas no formato quadrado (227×227 pixels), de acordo com os padrões de entrada exigidos pelo AlexNet. Todas as imagens foram salvas no formato vermelho-verde-azul (RGB) com resolução de 72 dpi. A rede foi configurada a utilizar, do total de imagens, 80% para treinamento, 10% para validação interna e 10% para teste na tarefa de identificar imagens de lesões cutâneas. No processo de aprendizagem, o AlexNet escolheu aleatoriamente o treinamento, validação interna e imagens de teste. Para o treinamento, definimos como 100 o número máximo de épocas para a identificação das lesões da LC (Figura 20) *versus* outras dermatoses (Figura 21). Além disso, as análises da rede foram realizadas no ambiente computacional MATLAB (www.mathworks.com).



Figura 20 - Exemplos de lesões de leishmaniose cutânea utilizadas no estudo.




Figura 21 - Exemplos de outros tipos de lesões cutâneas. (A) ectima; (B) erisipela; (C) piodermite; (D) sífilis terciária; (E) esporotricose; (F) líquen plano; (G) líquen simples crônico; (H) tinea corporis; (I) CEC; (J) ceratose actínica; (K) poroceratose; (L) insuficiência venosa.

4.3 Análise dos dados

No experimento com o AlexNet, realizamos três simulações. Primeiro, treinamos o algoritmo para aprender a distinguir lesões de LC de outras dermatoses. Em seguida, avaliamos o desempenho do algoritmo a partir de

matrizes de confusão, analisando o número de acertos e erros de identificação, bem como a acurácia, sensibilidade e especificidade médias da rede. Usamos as seguintes equações para calcular os indicadores de desempenho do ML:

$$\text{Acurácia} = \frac{VP + VN}{VP + FP + VN + FN}$$

$$\text{Sensibilidade} = \frac{VP}{VP + FN}$$

$$\text{Especificidade} = \frac{VN}{VN + FP}$$

VP = Verdadeiros positivos; VN = Verdadeiros negativos;
FP = Falsos positivos; FN = Falsos negativos.

As frequências e proporções foram calculadas com intervalos de confiança (binomial de Wilson com escore de 95%), utilizando o pacote 'Hmisc' no software computacional R 4.2.1, em conjunto com a interface RStudio 2023.03.1.446 (Newcombe, 1998; RSTUDIO TEAM, 2022; R CORE TEAM, 2022; Harrell; Dupont, 2023). Desse modo, os resultados foram apresentados por meio de tabelas descritivas e figuras ilustrativas.

4.4. Consideração Ética

Este estudo foi aprovado pelo Comitê de Ética e Pesquisa da Faculdade de Medicina da Universidade de Brasília, CAAE: 68696323.5.0000.5558 e número: 035700/2023.

5 RESULTADOS

5.1 Treino

As três simulações demonstraram progressos significativos, nos quais a acurácia da validação obteve bons resultados. O processo de treinamento do algoritmo foi concluído em 100 épocas (Figura 22). É possível observar que o AlexNet aprende com os novos dados, pois à medida que as épocas avançam, a acurácia dos dados aumenta e, conseqüentemente, as perdas diminuem.




Figura 22 - Progresso de treino da rede AlexNet. São apresentadas curvas de acurácia de treinamento, acurácia de validação, perda de treinamento e a perda de validação, com suavização aplicada para destacar tendências gerais no decorrer das iterações. O eixo horizontal representa as iterações, enquanto o eixo vertical representa os valores correspondentes das métricas. Os números internos são as épocas.

5.2 Desempenho do AlexNet

A simulação 1 apresentou 465 acertos e 26 erros, com acurácia de 94,70% (IC 95% 92,35–96,36). Sete imagens de lesões de LC foram confundidas com lesões de outros tipos de dermatoses, enquanto dezenove imagens de lesões de outros tipos de doenças foram confundidas com LC (Figura 23A).

A simulação 2 mostrou 469 acertos e 22 erros, com excelente acurácia de 95,51% (IC 95% 93,30–97,02). Das imagens erradas, três eram de lesões de LC que foram confundidas com lesões de outros tipos de dermatoses e dezenove eram de lesões de outros tipos de doenças de pele que foram confundidas com LC (Figura 23B).

Na simulação 3, obteve-se uma acurácia de 94,90%, representada por 466 acertos e 25 erros (IC 95% 92,59–96,52). Nessa simulação, três imagens de lesões de LC foram confundidas com outras dermatoses. Em contraste com as outras duas simulações, 22 imagens de outros tipos de lesões cutâneas foram confundidas com LC (Figura 23C).

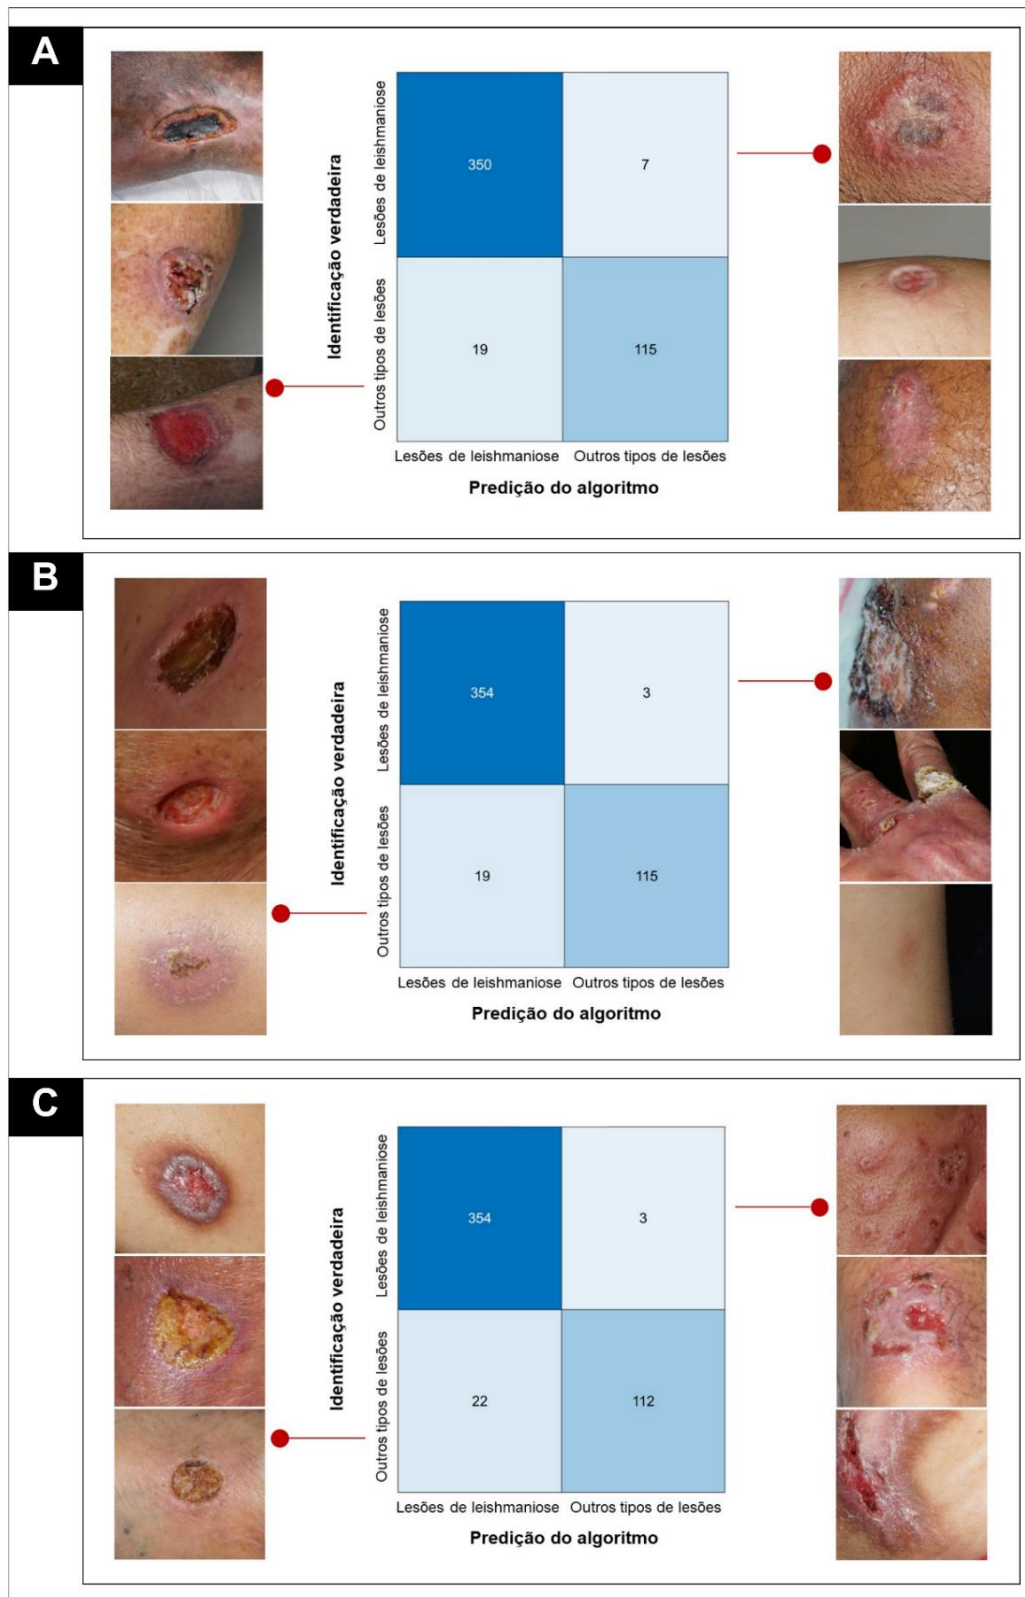


Figura 23 - Matrizes de confusão das simulações (lesões de LC × lesões de outras dermatoses) mostrando algumas das imagens de LC que foram erroneamente identificadas como outros tipos de lesões pela AlexNet e algumas imagens de outras dermatoses que foram identificadas como LC pela rede. (A) simulação 1; (B) simulação 2; (C) simulação 3.

Dentre as 60 imagens de lesões de outras dermatoses que foram confundidas com LC nas três simulações, as doenças de pele que apresentaram o maior percentual de erros foram: hanseníase (16,7%), ectima (11,6%), CBC (10,0%), erisipela (8,3%) e líquen plano (8,3%) (Figura 24). Os dados completos das imagens utilizadas pelo AlexNet com as predições de cada uma das três simulações encontram-se no Apêndice.




Figura 24 - Porcentagem de imagens de dermatoses identificadas incorretamente pela rede AlexNet. Acima de cada barra há o número exato da quantidade de identificações como LC. Nota: CBC e CEC de acordo com a Tabela 1.

Durante as três simulações, obtivemos uma acurácia média de validação de 95,04% (IC 95% 93,81–96,04), sensibilidade média de 98,78% (IC 95% 97,93-99,28) e especificidade média de 85,07% (IC 95% 81,25-88,22), indicando um excelente desempenho da rede treinada para a tarefa de identificação de lesões de LC. A Figura 25 mostra a acurácia, sensibilidade e especificidade de cada uma das simulações com seus respectivos intervalos de confiança.

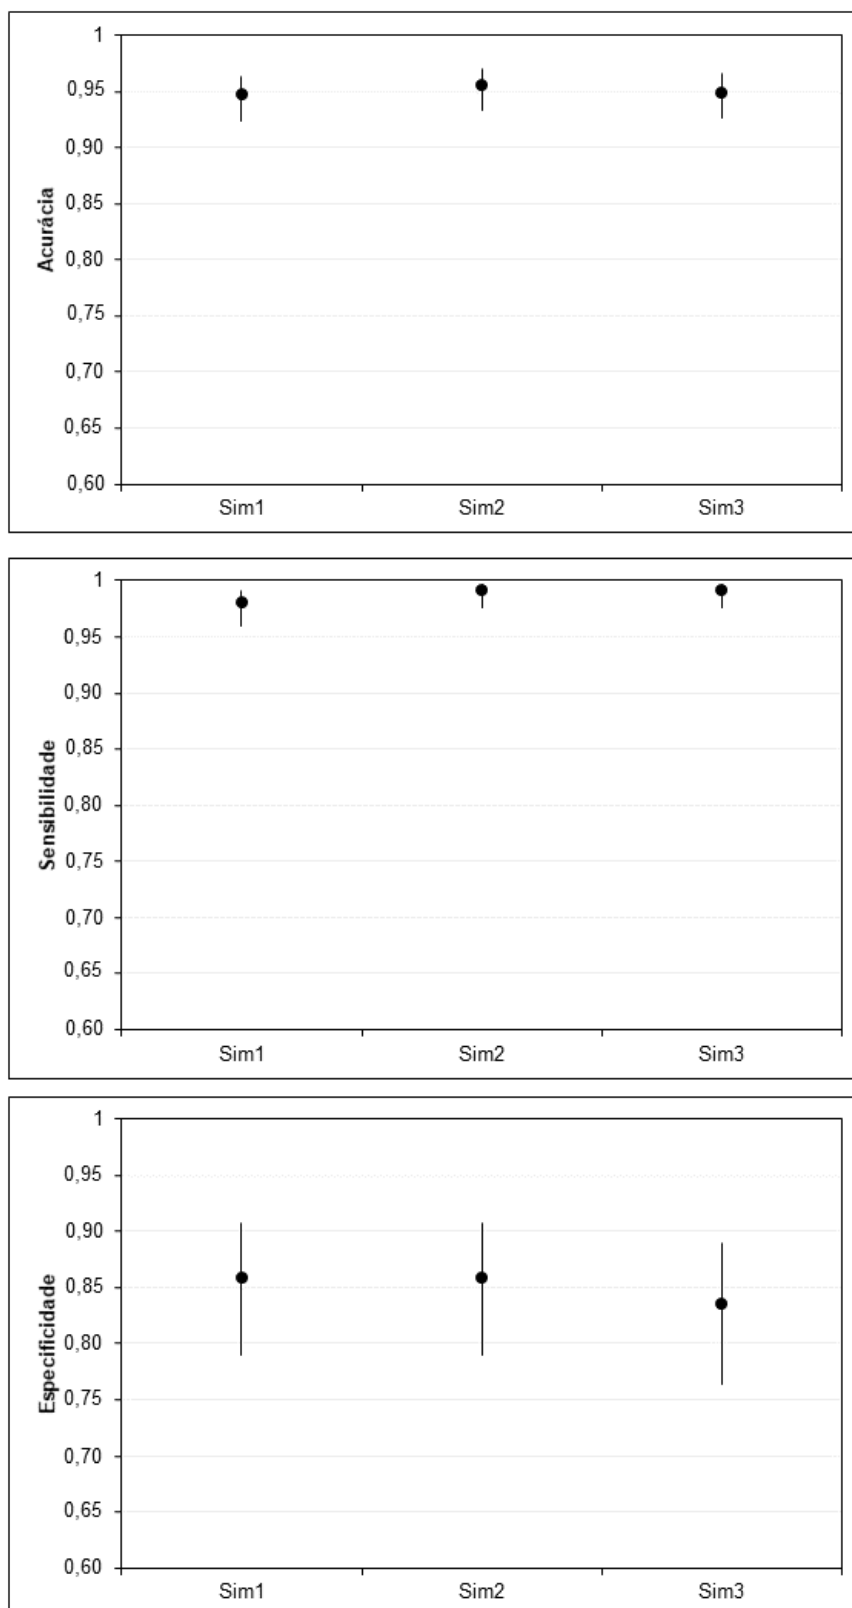


Figura 25 - Acurácia, sensibilidade e especificidade da rede AlexNet para identificação de imagens de lesões de LC com intervalos de confiança (barras) de Wilson de 95%. Nota: Sim = simulação.

6 DISCUSSÃO

Nossos resultados mostram um excelente desempenho do AlexNet na identificação de imagens de lesões de LC. Esses resultados abrem caminho para o desenvolvimento de um sistema de IA baseado em ML que pode facilitar o diagnóstico de lesões de LC, auxiliar os clínicos no diagnóstico diferencial de outras doenças de pele, promover diagnóstico mais rápido e tratamento oportuno e, conseqüentemente, ajudar a melhorar a qualidade de vida dos pacientes diagnosticados com LC.

O banco de dados deste estudo foi construído com base em uma coorte de pacientes atendidos no Ambulatório de Dermatologia do HUB, ao longo de 8 anos. Todas as lesões cutâneas foram fotografadas durante o primeiro contato dos pacientes. No entanto, as imagens só foram adicionadas ao banco de dados após o diagnóstico conclusivo da doença de pele (Litjens *et al.*, 2017; Latif *et al.*, 2019; Noureldeen *et al.*, 2023) e separadas em pastas de acordo com o tipo da doença. Assim, o diagnóstico foi baseado na classificação operacional do HUB. Esses dados mostram que o banco de dados é confiável e baseado em um protocolo de diagnóstico bem estabelecido permitindo uma classificação confiável das imagens das lesões de LC incluídas neste estudo, as quais foram utilizadas para identificação automatizada usando o AlexNet.

Tecnologias, intervenções médicas e testes diagnósticos não são perfeitos e devem ser avaliados antes da introdução nos serviços de saúde. Desse modo, estudos de acurácia diagnóstica são importantes para discriminar entre indivíduos infectados e não infectados (Abad-Franch, 2020). Essa capacidade pode ser quantificada por meio de métricas, como sensibilidade e especificidade. Além disso, os principais objetivos dos testes diagnósticos e outras formas de teste devem ser prevenir a morte precoce, diminuir o sofrimento e restaurar a saúde funcional. Logo, novas ferramentas que melhorem o diagnóstico, ofereçam suporte aos pacientes com a doença e auxiliem os clínicos na detecção de indivíduos doentes devem ser desenvolvidas (Bossuyt *et al.*, 2012; Borges, 2016).

A IA refere-se à capacidade de uma máquina simular a inteligência humana (Du-Harpur *et al.*, 2020). A IA introduz novos conceitos e soluções para resolver desafios complexos (Hamet; Tremblay, 2017). O ML envolve algoritmos e modelos estatísticos projetados para aprender a partir de exemplos e observações. Dessa forma, o ML pode reconhecer e inferir padrões, capacitando-o a executar tarefas sem exigir instruções explícitas de um operador humano (Du-Harpur *et al.*, 2020; Janiesch; Zschech; Heinrich, 2021). As técnicas baseadas em ML têm se mostrado bem-sucedidas em vários campos, incluindo aplicações biomédicas e médicas (El Naqa; Murphy, 2015; Du-Harpur *et al.*, 2020).

Durante o treinamento, os dados fluem através de uma rede iterativa no qual as ponderações são constantemente ajustadas, permitindo que a rede neural otimize sua capacidade de classificação (Du-Harpur *et al.*, 2020). O DL com múltiplas camadas de neurônios emergiu como a principal técnica de IA para processar dados de imagens complexas. O DL utiliza redes neurais artificiais para mapear entradas de imagens e saídas de diagnósticos sem o envolvimento explícito da engenharia humana. Deve-se notar que as CNN's são um tipo particular de DL que tem se mostrado bem-sucedida na classificação de dados de imagens. O uso de CNN's para classificação de imagens tem se tornado cada vez mais popular devido aos avanços em métodos computacionais como o AlexNet (Du-Harpur *et al.*, 2020; Young *et al.*, 2020), que utilizam o aprendizado de transferência de redes pré-treinadas para aprender com as imagens do conjunto de dados (Brasil, 2017). Classificar dados com CNN's é um processo fácil, econômico e computacionalmente eficiente. Na medicina, as CNN's têm sido usadas principalmente para diagnóstico visual na dermatologia, radiologia e patologia (Du-Harpur *et al.*, 2020).

Existem mais de 2.000 doenças de pele que afetam um terço da população mundial, constituindo uma carga significativa de cuidados de saúde (Choy *et al.*, 2023). A dermatologia tem o potencial de se beneficiar do uso da DL para melhorar o cuidado ao paciente. Assim, a combinação de IA e

métodos baseados em *hardware* pode aumentar as habilidades dos dermatologistas e desempenhar papel fundamental na melhoria do acesso e da qualidade do atendimento dermatológico, fornecendo suporte diagnóstico em tempo real durante as consultas clínicas (Young *et al.*, 2020). Choy *et al.* (2023) analisaram as condições cutâneas mais comuns, incluindo acne, psoríase, eczema, rosácea e urticária. Os algoritmos de DL têm acurácia estimada em torno de 90% para o diagnóstico dessas doenças (Choy *et al.*, 2023). Srinivasu *et al.* (2021) desenvolveram um método utilizando vários algoritmos de DL para classificar doenças dermatológicas não infecciosas. Esse estudo mostrou que o MobileNet V2 teve uma maior acurácia em dispositivos de computação leves. Goceri (2021) utilizou o MobileNet V2 em um aplicativo de celular com interface amigável e demonstrou que o método proposto diagnosticou as doenças dermatológicas com 94,76% de acurácia. AlSuwaidan (2023) avaliou o desempenho de seis CNN's (VGG16, EfficientNet, InceptionV3, MobileNet, NasNet e ResNet50) para as três condições dermatológicas mais comuns (eczema, dermatite atópica e psoríase) no Oriente Médio, sendo que o MobileNet apresentou a maior acurácia (95,7%). Li *et al.* (2023) também demonstraram o desempenho de diferentes CNN's para o diagnóstico de ceratose actínica com acurácia em torno de 92%. Bisla *et al.* (2019) empregaram a DL para classificação de melanoma, apresentando desempenho superior aos métodos comuns. Noureldeen *et al.* (2023) empregaram o modelo YOLOv5 para identificação da LC e obtiveram uma acurácia média de 70% na identificação das lesões cutâneas. Thieme *et al.* (2023) desenvolveram uma CNN para identificar as características das lesões de pele causadas pela varíola dos macacos, alcançando uma sensibilidade de aproximadamente 90%. Esses dados sugerem que os sistemas móveis de DL podem auxiliar os clínicos no diagnóstico acurado de lesões cutâneas. Além disso, os sistemas de IA poderiam ser uma forma de acelerar o processo de diagnóstico e reduzir a alta carga de trabalho diária, e as abordagens de DL têm proporcionado resultados altamente satisfatórios na análise de imagens para atingir esse objetivo (Marletta *et al.*, 2023).

Outros estudos utilizaram modelos de DL para o diagnóstico dermatológico e tiveram desempenho igual ou melhor que os dermatologistas (Han *et al.*, 2020). Atualmente, não há estudos que tenham analisado imagens de lesões de LC em comparação com outras doenças de pele causadas por infecções fúngicas, infecções bacterianas e doenças não infecciosas por meio da aplicação de uma rede neural pré-treinada, como a AlexNet. Neste estudo, mostramos que a rede de DL tem uma acurácia média de 95,04% para identificar imagens de lesões de LC de outras dermatoses. Portanto, o desempenho do algoritmo utilizado em nosso estudo poderá ajudar a melhorar o diagnóstico de LC com base em imagens de lesões cutâneas.

Observamos que hanseníase, ectima e CBC foram frequentemente confundidas com LC pelo AlexNet. As lesões da LC podem ter manifestações clínicas diversas, com morfologias atípicas, que podem estar associadas a diversos fatores, como patogenicidade, virulência e imunidade do hospedeiro (Gurel; Tekin; Uzun, 2020). O diagnóstico diferencial ainda representa um desafio, pois outras doenças podem se manifestar de forma semelhante à LC, como CBC, hanseníase, ectima e neoplasias malignas. Além disso, outras dermatoses podem ser confundidas com LC incluindo cromomicose, blastomicose, tuberculose cutânea, CEC, erisipela, herpes zoster, linfoma cutâneo, sífilis terciária, hanseníase, paracoccidomicose, lúpus, rosácea granulomatosa, reações persistentes a picadas de artrópodes, entre outras (Mitropoulos; Konidas; Durkin-Konidas, 2010; Handler *et al.*, 2015; Tirelli; Vernal; Roselino, 2017; Thieme *et al.*, 2023). Por isso, a LC é chamada de "a grande imitadora", pois pode assemelhar-se a vários tipos de doenças de pele (Gurel; Tekin; Uzun, 2020). Ademais, sabe-se que, quando são realizadas comparações múltiplas, espera-se um aumento na quantidade de erros do tipo 1 (Motulsky, 2014). Pela mesma lógica, ao comparar várias categorias, espera-se que apenas ao acaso algumas categorias apresentem maior taxa de falsos positivos do que outras. A presença de diversas doenças de pele na categoria "outras dermatoses" resulta em poucas imagens de cada tipo de agravo, o que pode dificultar o treinamento do algoritmo de IA para

hanseníase, ectima e CBC, aumentando a probabilidade de que uma determinada doença tenha uma alta taxa de falso positivos.

Embora esse estudo demonstre potencial para diferenciar a LC de outras lesões cutâneas através de DL, ele também apresenta limitações. O Ambulatório de Dermatologia do HUB é um centro de referência para LC, apesar disso, o perfil dos pacientes pode ser diferente do perfil dos pacientes atendidos na atenção primária, o que pode ter impacto na acurácia do teste (Al-Khateeb, 2020). Portanto, os resultados podem não ser totalmente aplicáveis à população em geral, uma vez que o perfil dos atendidos na atenção básica é diferente. Para contornar essa situação, poderá ser realizada uma amostragem que inclua pacientes da atenção primária. Outra limitação é o número de imagens para os dois grupos utilizados como banco de dados, principalmente para outras dermatoses, pois há menor proporção de pacientes encaminhados ao HUB e diagnosticados com outras dermatoses durante os anos de construção do banco de dados, visto que o hospital é referência para o diagnóstico da LC. No entanto, colaborações com outros centros dermatológicos para aumentar e diversificar o banco de dados de outras dermatoses pode ser uma possível solução.

É importante que a base de dados seja ampliada para incluir lesões de outras dermatoses e de LC de outros países, causadas por outras espécies de *Leishmania*, considerando que as lesões desse estudo são causadas principalmente por *L. braziliensis* e, ocasionalmente, por *L. amazonensis* e *L. guyanensis* (Barroso *et al.*, 2018; Carvalho *et al.*, 2022). Vale ressaltar que as lesões do LC do Velho Mundo diferem das lesões do Novo Mundo, que podem evoluir para placas hiperqueratóticas. Quando causadas por *L. tropica* ou *L. major*, as lesões podem se auto curar dentro de um ano e podem deixar cicatrizes. No entanto, se causada por *L. aethiopica*, a cicatrização pode levar anos e resultar em leishmaniose mucocutânea oronasal severa. As lesões de LC do Novo Mundo causadas por *L. mexicana* são menos graves e cicatrizam mais rapidamente em comparação com as lesões causadas por espécies de *Viannia*, que resultam em ulcerativas mais graves e leishmaniose mucocutânea (Nazzaro; Rovaris; Veraldi, 2014). Desse modo, a diversidade

de imagens de lesões cutâneas no banco de dados pode permitir que o algoritmo de IA distinga lesões de LC causadas por várias espécies de *Leishmania*. Recentemente, um sistema baseado em IA foi desenvolvido para detectar parasitos do gênero *Leishmania* em imagens microscópicas (Zare *et al.*, 2022). Logo, acreditamos que a IA pode aprimorar o diagnóstico de LC ao processar imagens macroscópicas e microscópicas de lesões cutâneas e parasitas, respectivamente. Essas inovações podem melhorar o diagnóstico parasitológico da LC, que continua sendo o padrão de referência, devido à sua alta especificidade.

Este trabalho construiu um modelo de DL utilizando imagens como unidade de análise e, portanto, esses resultados não podem ser extrapolados para concluir o diagnóstico. Assim, realizaremos um estudo de coorte que utiliza o modelo aqui construído para avaliar a acurácia desse instrumento na vida real. Além disso, variações na aquisição e qualidade da imagem, como zoom, foco, iluminação e presença de pelo, representam desafios para a implementação da IA em ambientes clínicos. A qualidade e o campo de visão da imagem da lesão cutânea podem ter um impacto significativo na acurácia, e o desempenho tende a melhorar na ausência de pelos (Li; Desrosiers; Liu, 2023). Nossa abordagem para enfrentar esse desafio é incorporar imagens de alta e baixa qualidade em nosso banco de dados. Utilizamos até 10 imagens de cada paciente, portanto, há um problema de não independência dos dados. Assim, duas perspectivas podem superar essa limitação: 1) aumentar o banco de imagens para utilizar apenas uma foto de cada paciente ou 2) aplicar modelos mistos generalizados (Bolker *et al.*, 2009; Miranda *et al.*, 2024) para lidar com problemas de não independência e convergência nos dados do banco de imagens. O modelo aqui apresentado utilizou a segmentação manual de imagens (recorte), porém, para construir um aplicativo de fácil utilização pelos profissionais de saúde, é necessário automatizar os processos de segmentação e redimensionamento, que serão realizados na coorte que está em construção.

7 CONCLUSÃO

- Nosso estudo verificou que o AlexNet tem uma acurácia de 95% na identificação de lesões de LC, o que é um valor altamente significativo para esse diagnóstico complexo.
- O diagnóstico automatizado de lesões de LC usando IA pode auxiliar os profissionais de saúde, melhorando a acurácia das avaliações clínicas em tempo real. Dessa forma, a IA pode ser uma ferramenta valiosa para beneficiar os serviços de saúde, facilitando o diagnóstico diferencial de lesões cutâneas.
- Esses achados contribuem para o desenvolvimento de um aplicativo móvel para auxiliar o diagnóstico da LC nos serviços de saúde. Além disso, esse estudo representa um avanço na utilização do DL como uma nova ferramenta diagnóstica na LC, com potencial para aplicação no diagnóstico de outras dermatoses infecciosas.
- Esse esforço colaborativo tem o potencial de contribuir para o diagnóstico precoce, diminuindo os impactos negativos na qualidade de vida dos indivíduos afetados, e para o tratamento oportuno da LC.

REFERÊNCIAS

ABBASS, H. What is artificial intelligence?. **IEEE Transactions on Artificial Intelligence**, v. 2, n. 2, p. 94-95, 2021.

ABAD-FRANCH, F. Chagas disease diagnosis and cure assessment: Getting formally hierarchical about a naturally hierarchical problem. **PLoS Neglected Tropical Diseases**, v. 14, n. 10, p. e0008751, 2020.

AKHOUNDI, M.; KUHLS, K.; CANNET, A.; VOTÝPKA, J.; MARTY, P.; DELAUNAY, P.; SERENO, D. A historical overview of the classification, evolution, and dispersion of Leishmania parasites and sandflies. **PLoS neglected tropical diseases**, v. 10, n. 3, p. e0004349, 2016.

AKAZAWA, M.; HASHIMOTO, K. Artificial intelligence in gynecologic cancers: Current status and future challenges—A systematic review. **Artificial Intelligence in Medicine**, v. 120, p. 102164, 2021.

ALSUWAIDAN, L. Deep Learning Based Classification of Dermatological Disorders. **Biomedical Engineering and Computational Biology**, v. 14, p. 11795972221138470, 2023.

AL-KHATEEB, B. Primary health care and family physicians provide frontline care to the dermatology patients during the era of COVID-19: Recommendations and future directions. **Journal of Family Medicine and Primary Care**, v. 9, n. 12, p. 5862, 2020.

ANVERSA, L.; TIBURCIO, M. G. S.; RICHINI-PEREIRA, V. B.; RAMIREZ, L. E. Human leishmaniasis in Brazil: A general review. **Revista da Associação Médica Brasileira**, v. 64, p. 281-289, 2018.

BAMOROVAT, M.; SHARIFI, I.; RASHEDI, E.; SHAFIIAN, A.; SHARIFI, F.; KHOSRAVI, A.; TAHMOURESI, A. A novel diagnostic and prognostic approach for unresponsive patients with anthroponotic cutaneous leishmaniasis using artificial neural networks. **PLoS One**, v. 16, n. 5, p. e0250904, 2021.

BARROSO, D. H.; GONÇALVES, R. T.; BARBOSA, J. S.; MOTTA, J. D. O. C.; FREIRE, G. S. M.; GOMES, C. M.; SAMPAIO, R. N. R. Meglumine antimoniate was associated with a higher cure rate than liposomal amphotericin B in the treatment of American tegumentary leishmaniasis: A retrospective cohort study from a Leishmania braziliensis-endemic area. **Frontiers in Cellular and Infection Microbiology**, p. 1426, 2022.

BARI, A. U.; RAHMAN, S. B. Many faces of cutaneous leishmaniasis. **Indian Journal of dermatology, venereology and leprology**, v. 74, p. 23, 2008.

BARI, A. U. Clinical spectrum of cutaneous leishmaniasis: an overview from Pakistan. **Dermatology online journal**, v. 18, n. 2, p. 4-4, 2012.

BAWEJA, H. S.; PARHAR, T. Leprosy lesion recognition using convolutional neural networks. In: **2016 International Conference on Machine Learning and Cybernetics (ICMLC)**. IEEE, p. 141-145, 2016.

BARROSO, D. H.; FALCÃO, S. D. A. C.; MOTTA, J. D. O. C. D.; SEVILHA DOS SANTOS, L.; TAKANO, G. H. S.; GOMES, C. M.; FAVALI, C. B. F.; LIMA, B. D.; SAMPAIO, R. N. R. PD-L1 may mediate T-cell exhaustion in a case of early diffuse leishmaniasis caused by *Leishmania (L.) amazonensis*. **Frontiers in immunology**, v. 9, p. 1021, 2018.

BECKER, A. S.; BLÜTHGEN, C.; SEKAGGYA-WILTSHIRE, C.; CASTELNUOVO, B.; KAMBUGU, A.; FEHR, J.; FRAUENFELDER, T. Detection of tuberculosis patterns in digital photographs of chest X-ray images using Deep Learning: feasibility study. **The International Journal of Tuberculosis and Lung Disease**, v. 22, n. 3, p. 328-335, 2018.

BISLA, D.; CHOROMANSKA, A.; BERMAN, R. S.; STEIN, J.A.; POLSKY, D. Towards automated melanoma detection with deep learning: Data purification and augmentation. In: **Proceedings of the IEEE/CVF conference on computer vision and pattern recognition workshops**. *ArXiv*. 2019.

BOSSUYT, P. M. M.; REITSMA, J. B.; LINNET, K.; MOONS, K. G. M. Beyond diagnostic accuracy: the clinical utility of diagnostic tests. **Clinical chemistry**, v. 58, n. 12, p. 1636-1643, 2012.

BORGES, L. Medidas de acurácia diagnóstica na pesquisa cardiovascular. **Int J Cardiovasc Sci**, v. 29, n. 3, p. 218-22, 2016.

BOLKER, B. M.; BROOKS, M. E.; CLARK, C. J.; GEANGE, S. W.; POULSEN, J. R.; STEVENS, M. H. H.; WHITE, J. S. S. Generalized linear mixed models: A practical guide for ecology and evolution. **Trends in ecology & evolution**, v. 24, n. 3, p. 127-135, 2009.

BRAGA, M. O. **Uma avaliação elaborada dos principais modelos de referência para classificação de imagens**. 45 f., il. Trabalho de conclusão de curso (Bacharelado em Engenharia da Computação) — Universidade de Brasília, Brasília, 2021.

BRASIL. Ministério da Saúde. **Manual de vigilância da leishmaniose tegumentar**. Secretaria de Vigilância em Saúde, Departamento de Vigilância das Doenças Transmissíveis. – Brasília: Ministério da Saúde, 2017.

Disponível em:

https://bvsmms.saude.gov.br/bvs/publicacoes/manual_vigilancia_leishmaniose_tegumentar.pdf. Acesso em: 01 dez. 2023.

BRASIL. Ministério da Saúde. **Guia de vigilância em saúde**. volume 2. Departamento de Articulação Estratégica de Vigilância em Saúde e Ambiente. – 6. ed. – Brasília: Ministério da Saúde, 2023. Disponível em: World Wide Web: https://bvsms.saude.gov.br/bvs/publicacoes/guia_vigilancia_saude_v2_6ed.pdf. Acesso em 01 dez. 2023.

BRASIL. Ministério da Saúde. **Distribuição da Leishmaniose Tegumentar**. 2023. Disponível em: <<https://www.gov.br/saude/pt-br/assuntos/saude-de-a-a-z/l/situacao-epidemiologica>>. Acesso em: 02 dez. 2023.

BURZA, S.; CROFT, S. L.; BOELAERT, M. Leishmaniasis. **Lancet**, v.392, p. 951-970, 2018.

CARVALHO, B. C.; VITAL, T.; OSIRO, J.; GOMES, C. M.; NORONHA, E.; DALLAGO, B.; ROSA, A. C.; CARVALHO, J. L.; HAGSTRÖM, L.; HECHT, M.; NITZ, N. Multiparametric analysis of host and parasite elements in new world tegumentary leishmaniasis. **Frontiers in Cellular and Infection Microbiology**, v. 12, p. 956112, 2022.

CASTILLO-GARIT, J. A.; FLORES-BALMASEDA, N.; ÁLVAREZ, O.; PÉREZ-DOÑATE, V.; TORRENS, F.; PÉREZ-GIMÉNEZ, F. Computational identification of chemical compounds with potential activity against *Leishmania amazonensis* using nonlinear machine learning techniques. **Current Topics in Medicinal Chemistry**, v. 18, n. 27, p. 2347-2354, 2018.

CHOY, S.P.; KIM, B. J.; PAOLINO, A.; TAN, W. R.; LIM, S. M. L.; SEO, J.; TAN, S. P.; FRANCIS, L.; TSAKOK, T.; SIMPSON, M.; BARKER, J. N. W. N.; LYNCH, M. D.; CORBETT, M. S.; SMITH, C. H.; MAHIL, S. K. Systematic review of deep learning image analyses for the diagnosis and monitoring of skin disease. **NPJ Digital Medicine**, v. 6, n. 1, p. 180, 2023.

CONCEIÇÃO-SILVA, F.; ALVES, C. R. **Leishmanioses do continente americano**. Editora Fiocruz, 2014.

DE, A.; SARDA, A.; GUPTA, S.; DAS, S. Use of artificial intelligence in dermatology. **Indian journal of dermatology**, v. 65, n. 5, p. 352, 2020.

DILDAR, M.; AKRAM, S.; IRFAN, M.; KHAN, H. U.; RAMZAN, M.; MAHMOOD, A. R.; ALSAIARI, S. A.; SAEED, A. H.; ALRADDADI, M. O.; MAHNASHI, M. H. Skin cancer detection: a review using deep learning techniques. **International journal of environmental research and public health**, v. 18, n. 10, p. 5479, 2021.

DICK, V.; SINZ, C.; MITTLBÖCK, M.; KITTLER, H.; TSCHANDL, P. Accuracy of computer-aided diagnosis of melanoma: a meta-analysis. **JAMA dermatology**, v. 155, n. 11, p. 1291-1299, 2019.

DOUBA, M. D.; ABBAS, O.; WALI, A.; NASSANY, J.; AOUF, A.; TIBBI, M. S.; KIBBI, A. G.; KURBAN, M. Chronic cutaneous leishmaniasis, a great mimicker with various clinical presentations: 12 years experience from Aleppo. **Journal of the European Academy of Dermatology and Venereology**, v. 26, n. 10, p. 1224-1229, 2012.

DU-HARPUR, X.; WATT, F. M.; LUSCOMBE, N. M.; LYNCH, M. D. What is AI? Applications of artificial intelligence to dermatology. **British Journal of Dermatology**, v. 183, n. 3, p. 423-430, 2020.

EL NAQA, I.; MURPHY, M. J. **What is machine learning?**. Springer International Publishing, 2015.

ERICKSON, B. J.; KORFIATIS, P.; AKKUS, Z.; KLINE, T. L. Machine learning for medical imaging. **Radiographics**, v. 37, n. 2, p. 505-515, 2017.

ESTEVA, A.; KUPREL, B.; NOVOA, R. A.; KO, J.; SWETTER, S. M.; BLAU, H. M.; THRUN, S. Dermatologist-level classification of skin cancer with deep neural networks. **nature**, v. 542, n. 7639, p. 115-118, 2017.

ESPAÑA, A. G.; PIMENTEL, M. I. F.; MIRANDA LYRA, J. P.; VALETE-ROSALINO, C. M.; LYRA, M. R. Description of the dermatoscopic features observed in sporotrichosis and American cutaneous leishmaniasis in a reference center in Rio de Janeiro, Brazil. **Anais Brasileiros de Dermatologia**, v. 98, n. 6, p. 764-773, 2023.

GONÇALVES, C. C. L. **Identificação automática de plantas invasoras em imagens aéreas**. Lisboa: ISCTE-IUL, 2019. Dissertação de mestrado. Disponível em: [www:<http://hdl.handle.net/10071/20313>](http://hdl.handle.net/10071/20313). Acesso em: 07 dez. 2023.

GOMES, C. M.; PAULA, N. A.; MORAIS, O. O.; SOARES, K. A.; ROSELINO, A. M.; SAMPAIO, R. N. Complementary exams in the diagnosis of American tegumentary leishmaniasis. **Anais brasileiros de dermatologia**, v. 89, p. 701-709, 2014.

GOCERI, E. Diagnosis of skin diseases in the era of deep learning and mobile technology. **Computers in Biology and Medicine**, v. 134, p. 104458, 2021.

GUREL, M. S.; TEKIN, B.; UZUN, S. Cutaneous leishmaniasis: A great imitator. **Clinics in dermatology**, v. 38, n. 2, p. 140-151, 2020.

GUREL, M. S.; ULUKANLIGIL, M.; OZBILGE, H. Cutaneous leishmaniasis in Sanliurfa: epidemiologic and clinical features of the last four years (1997–2000). **International journal of dermatology**, v. 41, n. 1, p. 32-37, 2002.

GURGEL-GONÇALVES, R.; KOMP, E.; CAMPBELL, L. P.; KHALIGHIFAR, A.; MELLEBRUCH, J.; MENDONÇA, V. J.; OWENS, H. L.; FELIX, K. C.; PETERSON, A. T.; RAMSEY, J. M. Automated identification of insect vectors of Chagas disease in Brazil and Mexico: The Virtual Vector Lab. **PeerJ**, v. 5, p. e3040, 2017.

HAMET, P.; TREMBLAY, J. Artificial intelligence in medicine. **Metabolism**, v. 69, p. S36-S40, 2017.

HAMIDA, A. B.; DEVANNE, M.; WEBER, J.; TRUNTZER, C.; DERANGÈRE, V.; GHIRINGHELLI, F.; FORESTIER, G.; WEMMERT, C. Deep learning for colon cancer histopathological images analysis. **Computers in Biology and Medicine**, v. 136, p. 104730, 2021.

HAN, S. S.; KIM, M. S.; LIM, W.; PARK, G. H.; PARK, I.; CHANG, S. E. Classification of the clinical images for benign and malignant cutaneous tumors using a deep learning algorithm. **Journal of Investigative Dermatology**, v. 138, n. 7, p. 1529-1538, 2018.

HAN, S. S.; MOON, I. J.; LIM, W.; SUH, I. S.; LEE, S. Y.; NA, J. I.; KIM, S. H.; CHANG, S. E. Keratinocytic skin cancer detection on the face using region-based convolutional neural network. **JAMA dermatology**, v. 156, n. 1, p. 29-37, 2020.

HANDLER, M. Z.; PATEL, P. A.; KAPILA, R.; AL-QUBATI, Y.; SCHWARTZ, R. A. Cutaneous and mucocutaneous leishmaniasis: Differential diagnosis, diagnosis, histopathology, and management. **Journal of the American Academy of Dermatology**, v. 73, n. 6, p. 911-926, 2015.

HAUG, C. J.; DRAZEN, J. M. Artificial intelligence and machine learning in clinical medicine, 2023. **New England Journal of Medicine**, v. 388, n. 13, p. 1201-1208, 2023.

HASHIMOTO, D. A.; WITKOWSKI, E.; GAO, L.; MEIRELES, O.; ROSMAN, G. Artificial intelligence in anesthesiology: current techniques, clinical applications, and limitations. **Anesthesiology**, v. 132, n. 2, p. 379-394, 2020.

HARRELL, F.; DUPONT, C. (2023). **Package ‘Hmisc’: Harrell miscellaneous**. Disponível em: <http://www.who.int/mediacentre/factsheets/fs340/en/>. Acesso em: 30 agos. 2023.

HERWALDT, B. L. Leishmaniasis. **Lancet**, v. 354, p. 1191-1199, 1999.

HERRERA-ACEVEDO, C.; PERDOMO-MADRIGAL, C.; MURATOV, E. N.; SCOTTI, L.; SCOTTI, M. T. Discovery of alternative chemotherapy options for Leishmaniasis through computational studies of Asteraceae. **ChemMedChem**, v. 16, n. 8, p. 1234-1245, 2021.

IFTIKHAR, N.; BARI, I.; EJAZ, A. Rare variants of cutaneous leishmaniasis: whitlow, paronychia, and sporotrichoid. **International journal of dermatology**, v. 42, n. 10, p. 807-809, 2003.

JANIESCH, C.; ZSCHECH, P.; HEINRICH, K. Machine learning and deep learning. **Electronic Markets**, v. 31, n. 3, p. 685-695, 2021.

JIANG, F. JIANG, Y.; ZHI, H.; DONG, Y.; LI, H.; MA, S.; WANG, Y.; DONG, Q.; SHEN, H.; WANG, Y. Artificial intelligence in healthcare: past, present and future. **Stroke and vascular neurology**, v. 2, n. 4, 2017.

JIMÉNEZ-LUNA, J.; GRISONI, F.; WESKAMP, N.; SCHNEIDER, G. Artificial intelligence in drug discovery: recent advances and future perspectives. **Expert opinion on drug discovery**, v. 16, n. 9, p. 949-959, 2021.

JOGAS, D. G. The tropics, science, and leishmaniasis: an analysis of the circulation of knowledge and asymmetries. **História, Ciências, Saúde-Manguinhos**, v. 24, p. 1051-1070, 2017.

KARINCAOGLU, Y.; ESREFOGLU, M.; OZCAN, H. Atypical clinical form of cutaneous leishmaniasis: erysipeloid form. **International journal of dermatology**, v. 43, n. 11, p. 827-829, 2004.

KAUL, V.; ENSLIN, S.; GROSS, S. A. History of artificial intelligence in medicine. **Gastrointestinal endoscopy**, v. 92, n. 4, p. 807-812, 2020.

KHALIGHIFAR, A.; KOMP, E.; RAMSEY, J. M.; GURGEL-GONÇALVES, R.; PETERSON, A. T. Deep learning algorithms improve automated identification of Chagas disease vectors. **Journal of medical entomology**, v. 56, n. 5, p. 1404-1410, 2019.

KONONENKO, I. Machine learning for medical diagnosis: history, state of the art and perspective. **Artificial Intelligence in medicine**, v. 23, n.1, p. 89-109, 2001.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G.E. ImageNet classification with deep convolutional neural networks. **Advances in neural information processing systems**, v. 25, 2012.

KUMAR, L.S.; HARIHARASITARAMAN, S.; NARAYANASAMY, K.; THINAKARAN, K.; MAHALAKSHMI, J.; PANDIMURUGAN, V. AlexNet

approach for early stage Alzheimer's disease detection from MRI brain images. **Materials Today: Proceedings**, v. 51, p. 58-65, 2022.

KULKARNI, S.; SENEVIRATNE, N.; BAIG, M. S.; KHAN, A. H. A. Artificial intelligence in medicine: where are we now?. **Academic radiology**, v. 27, n. 1, p. 62-70, 2020.

LATIF, J.; XIAO, C.; IMRAN, A.; TU, S. Medical imaging using machine learning and deep learning algorithms: a review. In: **2019 2nd International conference on computing, mathematics and engineering technologies (iCoMET)**. IEEE, p. 1-5, 2019.

LARIOS, G.; RIBEIRO, M.; ARRUDA, C.; OLIVEIRA, S. L.; CANASSA, T.; BAKER, M. J.; MARANGONI, B.; RAMOS, C.; CENA, C. A new strategy for canine visceral leishmaniasis diagnosis based on FTIR spectroscopy and machine learning. **Journal of Biophotonics**, v. 14, n. 11, p. e202100141, 2021.

LITJENS, G.; KOOI, T.; BEJNORDI, B. E.; SETIO, A. A. A.; CIOMPI, F.; GHAFLOORIAN, M.; LAAK, J. A. W. M. V. D.; GINNEKEN, B. V.; SÁNCHEZ, C. I. A survey on deep learning in medical image analysis. **Medical image analysis**, v. 42, p. 60-88, 2017.

LI, X.; DESROSIERS, C.; LIU, X. Deep neural forest for out-of-distribution detection of skin lesion images. **IEEE Journal of Biomedical and Health Informatics**, v. 27, n. 1, p. 157-165, 2022.

LI, L.; QIN, L.; XU, Z.; YIN, Y.; WANG, X.; KONG, B.; BAI, J.; LU, Y.; FANG, Z.; SONG, Q.; CAO, K.; LIU, D.; WANG, G.; XU, Q.; FANG, X.; ZHANG, S.; XIA, J.; XIA, J. Using artificial intelligence to detect COVID-19 and community-acquired pneumonia based on pulmonary CT: evaluation of the diagnostic accuracy. **Radiology**, v. 296, n. 2, p. E65-E71, 2020.

LIU, P. R.; LU, L.; ZHANG, J. Y.; HUO, T. T.; LIU, S. X.; YE, Z. W. Application of artificial intelligence in medicine: an overview. **Current Medical Science**, v. 41, n. 6, p. 1105-1115, 2021.

MAGOULAS, G. D.; PRENTZA, A. Machine learning in medical applications. In: **Advanced course on artificial intelligence**. Berlin, Heidelberg: Springer Berlin Heidelberg, 1999. p. 300-307.

MARLETTA, S.; L'IMPERIO, V.; ECCHER, A.; ANTONINI, P.; SANTONICCO, N.; GIROLAMI, I.; DEI TOS, A.P.; SBARAGLIA, M.; PAGNI, P.; BRUNELLI, M.; MARINO, A.; SCARPA, A.; MUNARI, E.; FUSCO, N.; PANTANOWITZ, L. Artificial intelligence-based tools applied to pathological diagnosis of microbiological diseases. **Pathology-Research and Practice**, p. 154362, 2023.

MARON, R.; WEICHENTHAL, M.; UTIKAL, J. S.; HEKLER, A.; BERKING, C.; HAUSCHILD, A.; ENK, A. H.; HAFERKAMP, S.; KLODE, J.; SCHADENDORF, D.; JANSEN, P.; HOLLAND-LETZ, T.; SCHILLING, B.; VON KALLE, C.; FRÖHLING, S.; GAISER, M. R.; HARTMANN, D.; GESIERICH, A.; KÄHLER, K. C.; WEHKAMP, U.; KAROGLAN, A.; BÄR, C.; BRINKER, T. J. Systematic outperformance of 112 dermatologists in multiclass skin cancer image classification by convolutional neural networks. **European Journal of Cancer**, v. 119, p. 57-65, 2019.

MIRANDA, V. L.; SOUZA, E. P.; BAMBIL, D.; KHALIGHIFAR, A.; PETERSON, A. T.; NASCIMENTO, F. A. O.; GURGEL-GONÇALVES, R.; ABAD-FRANCH, F. Cellphone-picture based automated identification of Chagas disease vectors: Effects of bug genus and image orientation on the performance of five machine-learning algorithms. **Ecological Informatics**, p. 102430, 2023.

MITROPOULOS, P.; KONIDAS, P.; DURKIN-KONIDAS, M. New World cutaneous leishmaniasis: updated review of current and future diagnosis and treatment. **Journal of the American Academy of Dermatology**, v. 63, n. 2, p. 309-322, 2010.

MOKNI, M. Leishmanioses cutanées. In: **Annales de Dermatologie et de Vénérologie**. Elsevier Masson, 2019. p. 232-246.

MOTTA, D.; SANTOS, A. Á. B.; WINKLER, I.; MACHADO, B. A. S.; PEREIRA, D. A. D. I.; CAVALCANTI, A. M.; FONSECA, E. O. L.; KIRCHNER, F.; BADARÓ, R. Application of convolutional neural networks for classification of adult mosquitoes in the field. **PloS one**, v. 14, n. 1, p. e0210829, 2019.

MOTA, L. A. A.; MIRANDA, R. R. Manifestações dermatológicas e otorrinolaringológicas na Leishmaniose. **Arquivos Internacionais de Otorrinolaringologia**, v. 15, p. 376-381, 2011.

MOTULSKY, H. **Intuitive biostatistics: a nonmathematical guide to statistical thinking**. Oxford University Press, USA, 2014.

MORAVVEJ, H.; BARZEGAR, M.; NASIRI, S.; ABOLHASANI, E.; MOHEBALI, M. Cutaneous leishmaniasis with unusual clinical and histological presentation: report of four cases. **Acta Medica Iranica**, p. 274-278, 2013.

MORAIS, M. C. C.; SILVA, D.; MILAGRE, M. M.; OLIVEIRA, M. T.; PEREIRA, T.; SILVA, J. S.; COSTA, L. D. F.; MINOPRIO, P.; JUNIOR, R. M. C.; GAZZINELLI, R.; LANA, M.; NAKAYA, H. I. Automatic detection of the

parasite *Trypanosoma cruzi* in blood smears using a machine learning approach applied to mobile phone images. **PeerJ**, v. 10, p. e13470, 2022.

NAZZARO, G.; ROVARIS, M.; VERALDI, S. Leishmaniasis: a disease with many names. **JAMA dermatology**, v. 150, n. 11, p. 1204-1204, 2014.

NAYARISSERI, A.; KHANDELWAL, R.; TANWAR, P.; MADHAVI, M.; SHARMA, D.; THAKUR, G.; SPECK-PLANCHE, A.; SINGH, S. K. Artificial intelligence, big data and machine learning approaches in precision medicine & drug discovery. **Current drug targets**, v. 22, n. 6, p. 631-655, 2021.

NENSA, F.; DEMIRCIOGLU, A.; RISCHPLER, C. Artificial intelligence in nuclear medicine. **Journal of Nuclear Medicine**, v. 60, n. Supplement 2, p. 29S-37S, 2019.

NEWCOMBE, R. G. Two-sided confidence intervals for the single proportion: comparison of seven methods. **Statistics in medicine**, v. 17, n. 8, p. 857-872, 1998.

NOURELDEEN, A. M.; MASOUD, K. S.; ALMAKHZOOM, O. A. Deep learning model for Cutaneous leishmaniasis detection and classification using Yolov5. **African Journal of Advanced Pure and Applied Sciences (AJAPAS)**, p. 270-280, 2023.

OJEDA-PAT, A.; MARTIN-GONZALEZ, A.; BRITO-LOEZA, C.; RUIZ-PIÑA, H.; RUIZ-SUAREZ, D. Effective residual convolutional neural network for Chagas disease parasite segmentation. **Medical & Biological Engineering & Computing**, v. 60, n. 4, p. 1099-1110, 2022.

OPAS. ORGANIZAÇÃO PAN-AMERICANA DA SAÚDE. **Leishmaniasis**. 2023. Disponível em:
<https://www.paho.org/pt/topicos/leishmaniose#:~:text=A%20leishmaniose%20%C3%A9%20end%C3%AAmica%20em,%3A%20Brasil%2C%20Col%C3%B4mbia%20e%20Peru>. Acesso em: 01 dez. 2023.

OPAS. ORGANIZAÇÃO PAN-AMERICANA DA SAÚDE. **Cutaneous and Mucosal Leishmaniasis**. 2023. Disponível em:
<https://www.paho.org/pt/topicos/leishmaniose/leishmaniose-cutanea-e-mucosa>. Acesso em: 01 dez. 2023.

PINHEIRO, A. B. S.; KURIZKY, P. S.; FERREIRA, M. D. F.; MOTA, M. A. D. S.; RIBEIRO, J. S.; OLIVEIRA FILHO, E. Z. D.; SOUZA, C. A.; BARROSO, D. H.; SAMPAIO, R. N. R.; GOMES, C. M. The accuracy of the Montenegro skin test for leishmaniasis in PCR-negative patients. **Revista da Sociedade Brasileira de Medicina Tropical**, v. 53, p. e20190433, 2020.

PK, F. A. What is artificial intelligence? **Learning Outcomes of Classroom Research**, p. 65, 1984. Disponível em: Neelam-MahaLakshmi-2021-Aspects-of-Artificial-Intelligence-In-KarthikeyanJ-Su-Hie-Ting-and-Yu-Jin-Ng-eds-Learning-Outcomes-of-Classroom-Research-p250-256-L-Ordine-Nuovo-Publication-India-978-93-92.pdf (researchgate.net). Acesso em: 03 dez. 2023.

QASHQAI, P.; VAHEDI, H.; AL-HADDAD, K. Applications of artificial intelligence in power electronics. In: **2019 IEEE 28th International Symposium on Industrial Electronics (ISIE)**. IEEE, p. 764-769, 2019.

RAJARAMAN, S.; SILAMUT, K.; HOSSAIN, M. A.; ERSOY, I.; MAUDE, R. J.; JAEGER, S.; THOMA, G. R.; ANTANI, S. K. Understanding the learned behavior of customized convolutional neural networks toward malaria parasite detection in thin blood smear images. **Journal of Medical Imaging**, v. 5, n. 3, p. 034501-034501, 2018.

RAMESH, A. N.; KAMBHAMPATI, C.; MONSON, J. R.; DREW, P. J. Artificial intelligence in medicine. **Annals of the Royal College of Surgeons of England**, v. 86, n. 5, p. 334, 2004.

REITHINGER, R.; DUJARDIN, J. C.; LOUZIR, H.; PIRMEZ, C.; ALEXANDER, B.; BROOKER, S. Cutaneous leishmaniasis. **The Lancet infectious diseases**, v. 7, n. 9, p. 581-596, 2007.

RStudio Team (2022). **RStudio: Integrated Development for R**. RStudio, PBC, Boston, MA. RStudio 2023.03.1.446. Disponível em: <https://posit.co/products/open-source/rstudio/>. Acesso em: 14 agos. 2023.

R Core Team. Disponível em: <https://www.R-project.org/>. Acesso em: 30 agos. 2023.

SAMADY, J. A.; SCHWARTZ, R. A. Old World cutaneous leishmaniasis. **International Journal of Dermatology**, v. 36, n. 3, p. 161-166, 1997.

SANCHEZ-PATIÑO, N.; TORIZ-VAZQUEZ, A.; HEVIA-MONTIEL, N.; PEREZ-GONZALEZ, J. Convolutional Neural Networks for Chagas' Parasite Detection in Histopathological Images. In: **2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)**. IEEE, p. 2732-2735, 2021.

SOUZA, E. P. D.; GOMES, C. M.; BARROSO, D. H.; MIRANDA, V. L. D.; GURGEL-GONÇALVES, R. Aplicações do Deep Learning para diagnóstico de doenças e identificação de insetos vetores. **Saúde em Debate**, v. 43, p. 147-154, 2019.

SOLOMON, M.; GREENBERGER, S.; BAUM, S.; PAVLOTSKY, F.; BARZILAI, A.; SCHWARTZ, E. Unusual forms of cutaneous leishmaniasis due to *Leishmania major*. **Journal of the European Academy of Dermatology and Venereology**, v. 30, n. 7, p. 1171-1175, 2016.

SRINIVASU, P. N.; SIVASAI, J. G.; IJAZ, M. F.; BHOI, A. K.; KIM, W.; KANG, J. J. Classification of skin disease using deep learning neural networks with MobileNet V2 and LSTM. **Sensors**, v. 21, n. 8, p. 2852, 2021.

STEVERDING, D. The history of leishmaniasis. **Parasites & vectors**, v. 10, n. 1, p. 1-10, 2017.

STEYVE, N.; STEVE, P.; GHISLAIN, M.; NDJAKOMO, S. Optimized real-time diagnosis of neglected tropical diseases by automatic recognition of skin lesions. **Informatics in Medicine Unlocked**, v. 33, p. 101078, 2022.

SCOTTI, M. T.; HERRERA-ACEVEDO, C.; MENEZES, R. P.; MARTIN, H. J.; MURATOV, E.; SILVA, Á. Í. D. S.; ALBUQUERQUE, F. E.; CAALDO, F. L.; COY-BARRERA, E.; SCOTTI, L. MolPredictX: Online biological activity predictions by machine learning models. **Molecular Informatics**, 2022.

THIEME, A. H.; ZHENG, Y.; MACHIRAJU, G.; SADEE, C.; MITTERMAIER, M.; GERTLER, M.; SALINAS, J.L.; SRINIVASAN, K.; GYAWALI, P.; CARRILLO-PEREZ, F.; CAPODICCI, A.; UHLIG, M.; HABENICHT, D.; LOSER, A.; KOHLER, M.; SHUESSLER, M.; KAUL, D.; GOLLRAD, J.; MA, J.; LIPPERT, C.; BILLICK, K.; BOGOCH, I.; HERNANDEZ-BOUSSARD, T.; GELDSETZER, P.; GEVAERT, O. A deep-learning algorithm to classify skin lesions from mpox virus infection. **Nature medicine**, v. 29, n. 3, p. 738-747, 2023.

THOMAIDOU, E. HOREV, L.; JOTKOWITZ, D.; ZAMIR, M.; INGBER, A.; ENK, C. D.; MOLHO-PESSACH, V. Lymphatic dissemination in cutaneous leishmaniasis after local treatment. **American Journal of Tropical Medicine and Hygiene**, v. 93, n. 4, p. 770, 2015.

TIRELLI, F.; VERNAL, S.; ROSELINO, A. M. Final diagnosis of 86 cases included in differential diagnosis of American tegumentary leishmaniasis in a Brazilian sample: a retrospective cross-sectional study. **Anais brasileiros de dermatologia**, v. 92, p. 642-648, 2017.

TORRECILHA, R. B. P.; UTSUNOMIYA, Y. T.; SILVA BATISTA, L. F.; BOSCO, A. M.; NUNES, C. M.; CIARLINI, P. C.; LAURENTI, M. D. Prediction of lymph node parasite load from clinical data in dogs with leishmaniasis: An application of radial basis artificial neural networks. **Veterinary parasitology**, v. 234, p. 13-18, 2017.

TORRES-GUERRERO, E.; QUINTANILLA-CEDILLO, M. R.; RUIZ-ESMENJAUD, J.; ARENAS, R. Leishmaniasis: a review. **F1000Research**, v. 6, 2017.

TURETZ, M. L.; MACHADO, P. R.; KO, A. I.; ALVES, F.; BITTENCOURT, A.; ALMEIDA, R. P.; MOBASHERY, N.; JOHNSON JR. W. D.; CARVALHO, E. M. Disseminated leishmaniasis: a new and emerging form of leishmaniasis observed in northeastern Brazil. **The Journal of infectious diseases**, v. 186, n. 12, p. 1829-1834, 2002.

VALE, E. C. S.; FURTADO, T. Leishmaniose tegumentar no Brasil: revisão histórica da origem, expansão e etiologia. **Anais Brasileiros de Dermatologia**, v. 80, p. 421-428, 2005.

WERNICK, M. N.; YANG, Y.; BRANKOV, J. G.; YOURGANOV, G.; STROTHER, S. C. Machine learning in medical imaging. **IEEE signal processing magazine**, v. 27, n. 4, p. 25-38, 2010.

WHO. WORLD HEALTH ORGANIZATION. **Leishmaniasis**. 2023. Disponível em: <https://www.who.int/news-room/questions-andanswers/item/leishmaniasis>. Acesso em: 01 dez. 2023.

YOUNG, A. T.; XIONG, M.; PFAU, J.; KEISER, M. J.; WEI, M. L. Artificial intelligence in dermatology: A primer. **Journal of Investigative Dermatology**, v. 140, n. 8, p. 1504-1512, 2020.

ZARE, M.; AKBARIALIABAD, H.; PARSAEI, H.; ASGARI, Q.; ALINEJAD, A.; BAHREINI, M. S.; HOSSEINI, S. H.; GHOFRANI-JAHROMI, M.; SHAHRIARIRAD, R.; AMIRMOEZZI, Y.; SHAHRIARIRAD, S.; ZEIGHAMI, A.; ABDOLLAHIFARD, G. A machine learning-based system for detecting leishmaniasis in microscopic images. **BMC infectious diseases**, v. 22, n. 1, p. 1-6, 2022.

APÊNDICE - Tabelas com as simulações e predições do algoritmo

SIMULAÇÃO 1

ID Photo	Predição do AlexNet
AFC_85802_LC (1).JPG'	Lesões de leishmaniose'
AFC_85802_LC (23).JPG'	Lesões de leishmaniose'
AFC_85802_LC (27).JPG'	Lesões de leishmaniose'
AFC_85802_LC (30).JPG'	Lesões de leishmaniose'
AFC_85802_LC (33).JPG'	Lesões de leishmaniose'
AFC_85802_LC(34).JPG'	Lesões de leishmaniose'
AFC_85802_LC (38).JPG'	Lesões de leishmaniose'
AFC_85802_LC (42).JPG'	Lesões de leishmaniose'
AFC_85802_LC (43).JPG'	Lesões de leishmaniose'
AFC_85802_LC (49).JPG'	Lesões de leishmaniose'
AFC_85802_LC (5).JPG'	Lesões de leishmaniose'
AFC_85802_LC (6).JPG'	Lesões de leishmaniose'
AFC_85802_LC (7).JPG'	Lesões de leishmaniose'
ACL_86710_LC (10).JPG'	Lesões de leishmaniose'
ACL_86710_LC (13).JPG'	Lesões de leishmaniose'
ACL_86710_LC (14).JPG'	Lesões de leishmaniose'
ACL_86710_LC (5).JPG'	Lesões de leishmaniose'
ACL_86710_LC (7).JPG'	Lesões de leishmaniose'
ACMB_78159_LC (18).JPG'	Lesões de leishmaniose'
ACMB_78159_LC (22).JPG'	Lesões de leishmaniose'
ACMB_78159_LC (23).JPG'	Lesões de leishmaniose'
ACMB_78159_LC (8).JPG'	Lesões de leishmaniose'
AMCJ_858695_LC (15).JPG'	Lesões de leishmaniose'
AMCJ_8595_LC (22).JPG'	Lesões de leishmaniose'
AMCJ_8595_LC (5).JPG'	Lesões de leishmaniose'
AMC_17194_LC (13).JPG'	Lesões de leishmaniose'
AMC_17194_LC (14).JPG'	Lesões de leishmaniose'
AMC_17194_LC (15).JPG'	Lesões de leishmaniose'
AMC_17194_LC (19).JPG'	Lesões de leishmaniose'
AMC_17194_LC (25).JPG'	Lesões de leishmaniose'
AMC_17194_LC (29).JPG'	Lesões de leishmaniose'
ADL_37588_LC (6).JPG'	Lesões de leishmaniose'
APS_88312_LC (12).JPG'	Lesões de leishmaniose'
APS_88312_LC (17).JPG'	Lesões de leishmaniose'
APS_88312_LC (21).JPG'	Lesões de leishmaniose'
APS_88312_LC (4).JPG'	Lesões de leishmaniose'
APS_88312_LC (7).JPG'	Lesões de leishmaniose'
AS-59419_LC (13).JPG'	Lesões de leishmaniose'
AS-59419_LC (14).JPG'	Lesões de leishmaniose'
AS-59419_LC (3).JPG'	Lesões de leishmaniose'

AS-59419_LC (7).JPG'	Lesões de leishmaniose'
ACRF_86823_LC (18).JPG'	Lesões de leishmaniose'
BON_84103_LC (4).JPG'	Lesões de leishmaniose'
BBOT_81948_LC (3).JPG'	Lesões de leishmaniose'
CC_85915_LC (13).JPG'	Lesões de leishmaniose'
CENS_86698_LC (4).JPG'	Outros tipos de lesões'
CENS_86698_LC (6).JPG'	Lesões de leishmaniose'
CCS_85871_LC (8).JPG'	Lesões de leishmaniose'
CSL_86726_LC (13).JPG'	Lesões de leishmaniose'
CSL_86726_LC (14).JPG'	Lesões de leishmaniose'
CSL_86726_LC (17).JPG'	Lesões de leishmaniose'
CSL_86726_LC (2).JPG'	Lesões de leishmaniose'
CSL_86726_LC (5).JPG'	Lesões de leishmaniose'
CJSS_80496_LC (7).JPG'	Lesões de leishmaniose'
CJSS_80496_LC (8).JPG'	Lesões de leishmaniose'
CC_85915_LC (1).JPG'	Lesões de leishmaniose'
DAAC_86670_LC (4).JPG'	Lesões de leishmaniose'
DOP_0029_LC (8).JPG'	Lesões de leishmaniose'
DOP_0029_LC (9).JPG'	Lesões de leishmaniose'
DOP_0029_LC (10).JPG'	Lesões de leishmaniose'
DOP_0029_LC (2).JPG'	Lesões de leishmaniose'
DOP_0029_LC (6).JPG'	Lesões de leishmaniose'
DEPS_88895_LC (3).JPG'	Lesões de leishmaniose'
DEPS_88895_LC (4).JPG'	Lesões de leishmaniose'
DSR_84714_LC (9).JPG'	Lesões de leishmaniose'
ERR_84688_LC (16).JPG'	Lesões de leishmaniose'
ERR_84688_LC (4).JPG'	Lesões de leishmaniose'
EFC_85786_LC (12).JPG'	Lesões de leishmaniose'
EFC_85786_LC (19).JPG'	Lesões de leishmaniose'
EFC_85786_LC (32).JPG'	Lesões de leishmaniose'
EFC_85786_LC (34).JPG'	Lesões de leishmaniose'
EFC_85786_LC (6).JPG'	Lesões de leishmaniose'
EFC_85786_LC (7).JPG'	Lesões de leishmaniose'
ESJ_84060_LC (22).JPG'	Lesões de leishmaniose'
ESJ_84060_LC (23).JPG'	Lesões de leishmaniose'
EOS_84813_LC (13).JPG'	Lesões de leishmaniose'
EOS_84813_LC (14).JPG'	Lesões de leishmaniose'
EOS_84813_LC (20).JPG'	Lesões de leishmaniose'
ERZ_88753_LC (2).JPG'	Lesões de leishmaniose'
EFO_82578_LC (4).JPG'	Lesões de leishmaniose'
ES_84182_LC (13).JPG'	Lesões de leishmaniose'
ES_84182_LC (16).JPG'	Lesões de leishmaniose'
ES_84182_LC (26).JPG'	Lesões de leishmaniose'
ES_84182_LC (4).JPG'	Lesões de leishmaniose'

ES_84182_LC (8).JPG'	Lesões de leishmaniose'
EPC_85132_LC (16).JPG'	Lesões de leishmaniose'
EPC_85132_LC (21).JPG'	Lesões de leishmaniose'
FSMA_84484_LC (13).JPG'	Outros tipos de lesões'
FSMA_84484_LC (8).JPG'	Lesões de leishmaniose'
FMS_84326_LC (11).JPG'	Lesões de leishmaniose'
FMS_84326_LC (12).JPG'	Lesões de leishmaniose'
FMS_84326_LC (17).JPG'	Lesões de leishmaniose'
FMS_84326_LC (27).JPG'	Lesões de leishmaniose'
FMS_84326_LC (7).JPG'	Lesões de leishmaniose'
FMS_84326_LC (9).JPG'	Lesões de leishmaniose'
FB_88089_LC (5).JPG'	Lesões de leishmaniose'
FCS_89328_LC (3).JPG'	Lesões de leishmaniose'
FMB_85484 (12).JPG'	Lesões de leishmaniose'
FMB_85485 (2).JPG'	Lesões de leishmaniose'
FMB_85486 (24).JPG'	Lesões de leishmaniose'
FMB_85487 (4).JPG'	Lesões de leishmaniose'
FFSS_83627_LC (10).JPG'	Lesões de leishmaniose'
FFSS_83627_LC (12).JPG'	Lesões de leishmaniose'
FFSS_83627_LC (14).JPG'	Lesões de leishmaniose'
FFSS_83627_LC (16).JPG'	Lesões de leishmaniose'
FFSS_83627_LC (18).JPG'	Lesões de leishmaniose'
FFSS_83627_LC (3).JPG'	Lesões de leishmaniose'
FFSS_83627_LC (8).JPG'	Lesões de leishmaniose'
FFSS_83627_LC (9).JPG'	Lesões de leishmaniose'
FMG_86975_LC (10).JPG'	Lesões de leishmaniose'
FMG_86975_LC (13).JPG'	Lesões de leishmaniose'
FMG_86975_LC (18).JPG'	Lesões de leishmaniose'
FMG_86975_LC (19).JPG'	Lesões de leishmaniose'
FMG_86975_LC (2).JPG'	Lesões de leishmaniose'
FEV_84692_LC (1).JPG'	Lesões de leishmaniose'
FEV_84692_LC (14).JPG'	Lesões de leishmaniose'
FEV_84692_LC (16).JPG'	Outros tipos de lesões'
FEV_84692_LC (17).JPG'	Lesões de leishmaniose'
FEV_84692_LC (20).JPG'	Lesões de leishmaniose'
FEV_84692_LC (25).JPG'	Lesões de leishmaniose'
FEV_84692_LC (7).JPG'	Lesões de leishmaniose'
FEV_84692_LC (8).JPG'	Lesões de leishmaniose'
FEG_86211_LC (6).JPG'	Lesões de leishmaniose'
FEG_86211_LC (7).JPG'	Lesões de leishmaniose'
FFM_85707 (4).JPG'	Lesões de leishmaniose'
FLB_85985_LC (20).JPG'	Lesões de leishmaniose'
FLB_85985_LC (22).JPG'	Lesões de leishmaniose'
GMM_85697_LC (10).JPG'	Lesões de leishmaniose'

GMM_85697_LC (16).JPG'	Lesões de leishmaniose'
GMM_85697_LC (17).JPG'	Lesões de leishmaniose'
GBS_84619 (1).JPG'	Lesões de leishmaniose'
GBS_84619 (2).JPG'	Lesões de leishmaniose'
GBS_84619 (4).JPG'	Outros tipos de lesões'
GGLS_86649_LC (2).JPG'	Lesões de leishmaniose'
GGLS_86649_LC (3).JPG'	Lesões de leishmaniose'
GAB_84015_LC (6).JPG'	Lesões de leishmaniose'
GAB_84015_LC (8).JPG'	Lesões de leishmaniose'
GFO_85492_LC (10).JPG'	Lesões de leishmaniose'
GFO_85492_LC (15).JPG'	Lesões de leishmaniose'
GFO_85492_LC (16).JPG'	Lesões de leishmaniose'
GSL_89766_LC (11).JPG'	Lesões de leishmaniose'
GSL_89766_LC (12).JPG'	Lesões de leishmaniose'
GSL_89766_LC (19).JPG'	Lesões de leishmaniose'
GLS_86995_LC (2).JPG'	Lesões de leishmaniose'
GLS_86995_LC (6).JPG'	Lesões de leishmaniose'
HVD_85328_LC (2).JPG'	Lesões de leishmaniose'
HIMG_28137_LC (11).JPG'	Lesões de leishmaniose'
HIMG_28137_LC (17).JPG'	Lesões de leishmaniose'
HIMG_28137_LC (18).JPG'	Lesões de leishmaniose'
HIMG_28137_LC (19).JPG'	Lesões de leishmaniose'
HIMG_28137_LC (5).JPG'	Lesões de leishmaniose'
HIMG_28137_LC (8).JPG'	Lesões de leishmaniose'
HVLR_8582_LC (4).JPG'	Lesões de leishmaniose'
HVLR_8582_LC (6).JPG'	Lesões de leishmaniose'
HVLR_8582_LC (7).JPG'	Lesões de leishmaniose'
IOSJ_81942_LC (2).JPG'	Lesões de leishmaniose'
ISO_88320_LC (3).JPG'	Lesões de leishmaniose'
JDC_88812_LC (1).JPG'	Lesões de leishmaniose'
JDC_88812_LC (11).JPG'	Lesões de leishmaniose'
JDC_88812_LC (13).JPG'	Lesões de leishmaniose'
JDC_88812_LC (2).JPG'	Lesões de leishmaniose'
JDC_88812_LC (8).JPG'	Lesões de leishmaniose'
JDN_64135_LC (5).JPG'	Lesões de leishmaniose'
JVA_85112_LC (6).JPG'	Lesões de leishmaniose'
JGS_88853_LC (8).JPG'	Lesões de leishmaniose'
JCSC_84455_LC (12).JPG'	Lesões de leishmaniose'
JCSC_84455_LC (13).JPG'	Lesões de leishmaniose'
JCSC_84455_LC (2).JPG'	Lesões de leishmaniose'
JCSC_84455_LC (3).JPG'	Lesões de leishmaniose'
JSVL_280_LC (4).JPG'	Lesões de leishmaniose'
JSVL_280_LC (5).JPG'	Lesões de leishmaniose'
JMN_88647_LC (11).JPG'	Lesões de leishmaniose'

JMN_88647_LC (9).JPG'	Lesões de leishmaniose'
JRS_86521_LC (1).JPG'	Lesões de leishmaniose'
JRS_86521_LC (3).JPG'	Lesões de leishmaniose'
JFFL_83861_LC (5).JPG'	Lesões de leishmaniose'
JFFL_83861_LC (6).JPG'	Lesões de leishmaniose'
JLBD_84395_LC (10).JPG'	Lesões de leishmaniose'
JLBD_84395_LC (5).JPG'	Lesões de leishmaniose'
JPCF_86700_LC (9).JPG'	Lesões de leishmaniose'
JVBC_86562_LC (1).JPG'	Lesões de leishmaniose'
JVBC_86562_LC (2).JPG'	Lesões de leishmaniose'
JVBC_86562_LC (3).JPG'	Lesões de leishmaniose'
JCB_80850_LC (4).JPG'	Lesões de leishmaniose'
JFS_86426_LC (11).JPG'	Lesões de leishmaniose'
JFS_86426_LC (13).JPG'	Lesões de leishmaniose'
JFS_86426_LC (5).JPG'	Lesões de leishmaniose'
JFS_86426_LC (6).JPG'	Lesões de leishmaniose'
JECG_75788_LC (3).JPG'	Lesões de leishmaniose'
JECG_75788_LC (7).JPG'	Lesões de leishmaniose'
JONF_86371_LC (1).JPG'	Lesões de leishmaniose'
JONF_86371_LC (3).JPG'	Lesões de leishmaniose'
JONF_86371_LC (7).JPG'	Lesões de leishmaniose'
JONF_86371_LC (9).JPG'	Lesões de leishmaniose'
JRBS_7840549_LC (1).JPG'	Lesões de leishmaniose'
JRBS_78549_LC (2).JPG'	Lesões de leishmaniose'
JRC_81129_LC (5).JPG'	Lesões de leishmaniose'
JAS_84644_LC (6).JPG'	Lesões de leishmaniose'
JAS_84644_LC (8).JPG'	Lesões de leishmaniose'
JAS_8484644_LC (9).JPG'	Lesões de leishmaniose'
JMB_8480766_LC (14).JPG'	Lesões de leishmaniose'
JMB_84766_LC (4).JPG'	Lesões de leishmaniose'
JMB_84766_LC (5).JPG'	Lesões de leishmaniose'
JMB_84766_LC (6).JPG'	Lesões de leishmaniose'
JRC_81129_LC (3).JPG'	Lesões de leishmaniose'
JRC_81129_LC (8).JPG'	Lesões de leishmaniose'
JBO_83471_LC (6).JPG'	Lesões de leishmaniose'
JHF_05676_LC (2).JPG'	Lesões de leishmaniose'
KGMS_85297_LC (2).JPG'	Lesões de leishmaniose'
LTM_86226_LC (4).JPG'	Lesões de leishmaniose'
LJBC_84025_LC (12).JPG'	Lesões de leishmaniose'
LJBC_84025_LC (4).JPG'	Lesões de leishmaniose'
LGT_84389_LC (1).JPG'	Lesões de leishmaniose'
LGT_84389_LC (2).JPG'	Lesões de leishmaniose'
LGT_84389_LC (3).JPG'	Lesões de leishmaniose'
LGT_84389_LC (5).JPG'	Lesões de leishmaniose'

LGT_84389_LC (8).JPG'	Lesões de leishmaniose'
LTOS_82397_LC (2).JPG'	Lesões de leishmaniose'
LCC_86958 (1).JPG'	Lesões de leishmaniose'
LPM_82575_LC (2).JPG'	Lesões de leishmaniose'
LFTLG_85336_LC (1).JPG'	Lesões de leishmaniose'
LFTLG_85336_LC (8).JPG'	Lesões de leishmaniose'
MCAS_84096_LC (2).JPG'	Lesões de leishmaniose'
MAC_85420_LC (12).JPG'	Lesões de leishmaniose'
MAC_85420_LC (8).JPG'	Lesões de leishmaniose'
MAPB_86299_LC (5).JPG'	Outros tipos de lesões'
MWMN_84238_LC (1).JPG'	Lesões de leishmaniose'
MWMN_84238_LC (11).JPG'	Lesões de leishmaniose'
MWMN_84238_LC (13).JPG'	Lesões de leishmaniose'
MWMN_8442238_LC (2).JPG'	Lesões de leishmaniose'
MAC_84826_LC (1).JPG'	Lesões de leishmaniose'
MAC_84826_LC (12).JPG'	Lesões de leishmaniose'
MAC_84826_LC (15).JPG'	Lesões de leishmaniose'
MAC_84826_LC (2).JPG'	Lesões de leishmaniose'
MAC_84826_LC (9).JPG'	Lesões de leishmaniose'
MBBR_85993_LC (4).JPG'	Lesões de leishmaniose'
MBBR_85993_LC (5).JPG'	Lesões de leishmaniose'
MBBR_85993_LC (7).JPG'	Lesões de leishmaniose'
MCAR_85976_LC (10).JPG'	Lesões de leishmaniose'
MCAR_85976_LC (14).JPG'	Lesões de leishmaniose'
MCAR_85976_LC (4).JPG'	Lesões de leishmaniose'
MCPS_81271_LC (7).JPG'	Lesões de leishmaniose'
MHCS_85704_LC (4).JPG'	Lesões de leishmaniose'
MMF_85778_LC (13).JPG'	Lesões de leishmaniose'
MMF_85778_LC (14).JPG'	Lesões de leishmaniose'
MMF_85778_LC (18).JPG'	Lesões de leishmaniose'
MMF_85778_LC (23).JPG'	Lesões de leishmaniose'
MMLS_84879_LC (1).JPG'	Lesões de leishmaniose'
MMLS_84879_LC (10).JPG'	Lesões de leishmaniose'
MMLS_84879_LC (2).JPG'	Lesões de leishmaniose'
MMLS_84879_LC (7).JPG'	Lesões de leishmaniose'
MMLS_84879_LC (8).JPG'	Lesões de leishmaniose'
MRSS_85199_LC (3).JPG'	Lesões de leishmaniose'
MSBS_82587_LC (2).JPG'	Lesões de leishmaniose'
MSBS_82587_LC .JPG'	Lesões de leishmaniose'
MTJA_56036_LC (17).JPG'	Lesões de leishmaniose'
MTJA_56036_LC (18).JPG'	Lesões de leishmaniose'
MTJA_56036_LC (2).JPG'	Lesões de leishmaniose'
MTJA_56036_LC (4).JPG'	Lesões de leishmaniose'
MATB_26499_LC (3).JPG'	Lesões de leishmaniose'

MATB_26499_LC (4).JPG'	Lesões de leishmaniose'
MATB_26499_LC (7).JPG'	Lesões de leishmaniose'
MAD_86106_LC (3).JPG'	Lesões de leishmaniose'
MAD_86106_LC (5).JPG'	Lesões de leishmaniose'
MAD_86106_LC (9).JPG'	Lesões de leishmaniose'
MABC_84017_LC (2).JPG'	Lesões de leishmaniose'
MABC_84017_LC (3).JPG'	Lesões de leishmaniose'
MBJ_70782_LC (5).JPG'	Lesões de leishmaniose'
MOA_85592_LC (27).JPG'	Lesões de leishmaniose'
MOA_85592_LC (34).JPG'	Lesões de leishmaniose'
MOA_85592_LC (36).JPG'	Lesões de leishmaniose'
MOA_85592_LC (37).JPG'	Lesões de leishmaniose'
MOA_85592_LC (40).JPG'	Lesões de leishmaniose'
MOA_85592_LC (41).JPG'	Lesões de leishmaniose'
MOA_85592_LC (46).JPG'	Lesões de leishmaniose'
MOA_85592_LC (47).JPG'	Lesões de leishmaniose'
MOA_85592_LC (48).JPG'	Lesões de leishmaniose'
MOA_88322_LC (4).JPG'	Lesões de leishmaniose'
MPS_88873_LC (15).JPG'	Lesões de leishmaniose'
MPS_88873_LC (17).JPG'	Lesões de leishmaniose'
MPS_88873_LC (6).JPG'	Lesões de leishmaniose'
MSB_88173_LC (16).JPG'	Lesões de leishmaniose'
MSB_88173_LC (2).JPG'	Lesões de leishmaniose'
MSB_88173_LC (5).JPG'	Lesões de leishmaniose'
MSB_88173_LC (6).JPG'	Lesões de leishmaniose'
MSB_78556_LC (2).JPG'	Lesões de leishmaniose'
MLM_86568_LC (13).JPG'	Lesões de leishmaniose'
MLM_86568_LC (2).JPG'	Lesões de leishmaniose'
MLM_86568_LC (9).JPG'	Lesões de leishmaniose'
NBS_84628_LC (10).JPG'	Lesões de leishmaniose'
NBS_84628_LC (11).JPG'	Lesões de leishmaniose'
NBS_84628_LC (5).JPG'	Lesões de leishmaniose'
NBS_84628_LC (6).JPG'	Lesões de leishmaniose'
NBS_84628_LC (8).JPG'	Lesões de leishmaniose'
NCA_20888_LC (1).JPG'	Lesões de leishmaniose'
NCA_20888_LC (2).JPG'	Lesões de leishmaniose'
NSA_84016_LC (12).JPG'	Lesões de leishmaniose'
NSA_84016_LC (14).JPG'	Lesões de leishmaniose'
NSA_84016_LC (27).JPG'	Lesões de leishmaniose'
NSA_84016_LC (5).JPG'	Lesões de leishmaniose'
NRR_86696_LC (4).JPG'	Lesões de leishmaniose'
NRR_86696_LC (5).JPG'	Lesões de leishmaniose'
OLL_89703_LC (4).JPG'	Lesões de leishmaniose'
OSL_27557_LC (5).JPG'	Lesões de leishmaniose'

PKMLC_84031_LC (10).JPG'	Lesões de leishmaniose'
PKMLC_84031_LC (17).JPG'	Lesões de leishmaniose'
PKMLC_84031_LC (6).JPG'	Lesões de leishmaniose'
PKMLC_84031_LC (18).JPG'	Lesões de leishmaniose'
RBS_86925_LC (12).JPG'	Lesões de leishmaniose'
RBS_86925_LC (3).JPG'	Lesões de leishmaniose'
RBS_86925_LC (7).JPG'	Lesões de leishmaniose'
RSS_84951_LC (1).JPG'	Lesões de leishmaniose'
RSS_84951_LC (10).JPG'	Lesões de leishmaniose'
RSS_84951_LC (8).JPG'	Lesões de leishmaniose'
RCM_86771_LC (12).JPG'	Lesões de leishmaniose'
RCM_86771_LC (3).JPG'	Lesões de leishmaniose'
RCM_86771_LC (4).JPG'	Lesões de leishmaniose'
RPA_87608_LC (1).JPG'	Lesões de leishmaniose'
RPA_87608_LC (15).JPG'	Lesões de leishmaniose'
RPA_87608_LC (16).JPG'	Lesões de leishmaniose'
RPA_87608_LC (18).JPG'	Lesões de leishmaniose'
RPA_87608_LC (8).JPG'	Lesões de leishmaniose'
RLS_80973_LC (17).JPG'	Lesões de leishmaniose'
RLS_80973_LC (22).JPG'	Lesões de leishmaniose'
RLS_80973_LC (24).JPG'	Lesões de leishmaniose'
RLS_80973_LC (8).JPG'	Lesões de leishmaniose'
SBD_85168_LC (15).JPG'	Lesões de leishmaniose'
SBD_85168_LC (3).JPG'	Lesões de leishmaniose'
SBD_85168_LC (6).JPG'	Lesões de leishmaniose'
SRSF_86531_LC (5).JPG'	Lesões de leishmaniose'
SRSF_86531_LC (7).JPG'	Lesões de leishmaniose'
SRSF_86531_LC (8).JPG'	Lesões de leishmaniose'
SCP_78739_LC (4).JPG'	Lesões de leishmaniose'
SSRL_84717_LC (6).JPG'	Lesões de leishmaniose'
SSRL_84717_LC (9).JPG'	Lesões de leishmaniose'
STSP_22520_LC (1).JPG'	Outros tipos de lesões'
STSP_22520_LC (2).JPG'	Outros tipos de lesões'
STSP_22520_LC (5).JPG'	Lesões de leishmaniose'
TAB_86523_LC (6).JPG'	Lesões de leishmaniose'
TAB_86523_LC (9).JPG'	Lesões de leishmaniose'
TPV_84919_LC (2).JPG'	Lesões de leishmaniose'
TPV_84919_LC (8).JPG'	Lesões de leishmaniose'
VJN_85150_LC (15).JPG'	Lesões de leishmaniose'
VAN_90245_LC (4).JPG'	Lesões de leishmaniose'
VAN_90245_LC (7).JPG'	Lesões de leishmaniose'
VSO_18786_LC (3).JPG'	Lesões de leishmaniose'
VSO_18786_LC (4).JPG'	Lesões de leishmaniose'
VSO_18786_LC (15).JPG'	Lesões de leishmaniose'

VSO_18786_LC (6).JPG'	Lesões de leishmaniose'
VDS_88810_LC (1).JPG'	Lesões de leishmaniose'
VDS_88810_LC (3).JPG'	Lesões de leishmaniose'
VDS_88810_LC (5).JPG'	Lesões de leishmaniose'
WASL_85534_LC (7).JPG'	Lesões de leishmaniose'
WBS_78712_LC (1).JPG'	Lesões de leishmaniose'
WBS_78712_LC (15).JPG'	Lesões de leishmaniose'
WBS_78712_LC (5).JPG'	Lesões de leishmaniose'
WBS_78712_LC (7).JPG'	Lesões de leishmaniose'
MLF_83529_CEC (3).JPG'	Lesões de leishmaniose'
ASM_36829_CEC (13).JPG'	Outros tipos de lesões'
ASM_36829_CEC (4).JPG'	Outros tipos de lesões'
ASM_36829_CEC (7).JPG'	Lesões de leishmaniose'
ASM_36829_CEC (8).JPG'	Lesões de leishmaniose'
ADE_85056_ECZ (13).JPG'	Outros tipos de lesões'
ADE_85056_ECZ (15).JPG'	Outros tipos de lesões'
ADE_85056_ECZ (7).JPG'	Lesões de leishmaniose'
ABS_85306_IVC (5).JPG'	Outros tipos de lesões'
ABS_85306_IVC (7).JPG'	Outros tipos de lesões'
AJB_86684_IVC (3).JPG'	Outros tipos de lesões'
AJB_86684_IVC (4).JPG'	Outros tipos de lesões'
CNM_85338_HAN (1).JPG'	Outros tipos de lesões'
CNM_85338_HAN (17).JPG'	Outros tipos de lesões'
CNM_85338_HAN (2).JPG'	Outros tipos de lesões'
CNM_85338_HAN (25).JPG'	Outros tipos de lesões'
CLS_35167_VSL (13).JPG'	Outros tipos de lesões'
DSC_47487_LFC (1).JPG'	Outros tipos de lesões'
EAM_89659_HAN (11).JPG'	Lesões de leishmaniose'
EAM_89659_HAN (13).JPG'	Outros tipos de lesões'
EAM_89659_HAN (18).JPG'	Outros tipos de lesões'
EAM_89659_HAN (2).JPG'	Lesões de leishmaniose'
EAM_89659_HAN (20).JPG'	Lesões de leishmaniose'
EAM_89659_HAN (24).JPG'	Outros tipos de lesões'
EAM_89659_HAN (25).JPG'	Outros tipos de lesões'
EAM_89659_HAN (26).JPG'	Outros tipos de lesões'
EAM_89659_HAN (30).JPG'	Outros tipos de lesões'
EAM_89659_HAN (31).JPG'	Outros tipos de lesões'
EAM_89659_HAN (34).JPG'	Lesões de leishmaniose'
EAM_89659_HAN (4).JPG'	Lesões de leishmaniose'
EAM_89659_HAN (7).JPG'	Outros tipos de lesões'
ECC_88279_EPT (9).JPG'	Outros tipos de lesões'
EMN_11153_ECT (10).JPG'	Lesões de leishmaniose'
EMN_11153_ECT (2).JPG'	Outros tipos de lesões'
EMN_11153_ECT (3).JPG'	Outros tipos de lesões'

EDL_85289_EPF (1).JPG'	Outros tipos de lesões'
EDL_85289_EPF (2).JPG'	Outros tipos de lesões'
EBN_85447_CBC (2).JPG'	Outros tipos de lesões'
EBN_85447_CBC (7).JPG'	Outros tipos de lesões'
EBN_85447_CBC (9).JPG'	Lesões de leishmaniose'
GAN_49596_IVC (3).JPG'	Outros tipos de lesões'
GAN_49596_IVC (4).JPG'	Outros tipos de lesões'
GAN_49596_IVC (7).JPG'	Outros tipos de lesões'
GAN_49596_IVC (1).JPG'	Outros tipos de lesões'
GAN_49596_IVC (14).JPG'	Outros tipos de lesões'
GAN_49596_IVC (15).JPG'	Outros tipos de lesões'
GAN_49596_IVC (17).JPG'	Outros tipos de lesões'
GAN_49596_IVC (2).JPG'	Outros tipos de lesões'
GAN_4932596_IVC (20).JPG'	Outros tipos de lesões'
GAN_49596_IVC (22).JPG'	Outros tipos de lesões'
GAN_49596_IVC (23).JPG'	Outros tipos de lesões'
GAN_49596_IVC (9).JPG'	Outros tipos de lesões'
IMM_86646_SIT (5).JPG'	Outros tipos de lesões'
IMM_86646_SIT (8).JPG'	Outros tipos de lesões'
IMM_86646_SIT (9).JPG'	Outros tipos de lesões'
INS_90188_CBM (10).JPG'	Outros tipos de lesões'
INS_90188_CBM (15).JPG'	Outros tipos de lesões'
INS_90188_CBM (18).JPG'	Outros tipos de lesões'
INS_90188_CBM (21).JPG'	Outros tipos de lesões'
INS_90188_CBM (27).JPG'	Outros tipos de lesões'
INS_90188_CBM (29).JPG'	Outros tipos de lesões'
INS_90188_CBM (3).JPG'	Lesões de leishmaniose'
INS_90188_CBM (34).JPG'	Outros tipos de lesões'
INS_90188_CBM (35).JPG'	Outros tipos de lesões'
INS_90188_CBM (4).JPG'	Outros tipos de lesões'
IMC_83543_IVC (5).JPG'	Outros tipos de lesões'
IMC_83543_IVC (8).JPG'	Outros tipos de lesões'
JGR_84742_LSC (5).JPG'	Outros tipos de lesões'
JAF_86633_ECT (20).JPG'	Lesões de leishmaniose'
JAF_86633_ECT (29).JPG'	Outros tipos de lesões'
JFA_88020_LSC (16).JPG'	Outros tipos de lesões'
JFA_88020_LSC (1).JPG'	Outros tipos de lesões'
JRR_55758_PCT (5).JPG'	Outros tipos de lesões'
LCSP_88140_ECT (32).JPG'	Outros tipos de lesões'
LTF_86784_HAN (1).JPG'	Lesões de leishmaniose'
LTF_86784_HAN (3).JPG'	Lesões de leishmaniose'
LTF_86784_HAN (5).JPG'	Outros tipos de lesões'
LAC_84233_PDT (11).JPG'	Outros tipos de lesões'
MMA_88125_IVC (5).JPG'	Outros tipos de lesões'

MMA_88125_IVC (8).JPG'	Outros tipos de lesões'
MPV_26799_CBC (1).JPG'	Outros tipos de lesões'
MPV_26799_CBC (6).JPG'	Lesões de leishmaniose'
MRAJ_88204 (5).JPG'	Outros tipos de lesões'
MGAL_86901_EPT (2).JPG'	Outros tipos de lesões'
MFMS_26609_ECT (1).JPG'	Outros tipos de lesões'
MFMS_26609_ECT (11).JPG'	Outros tipos de lesões'
MFMS_26609_ECT (7).JPG'	Outros tipos de lesões'
MFMS_26609_ECT (9).JPG'	Outros tipos de lesões'
MFRS_88083_ECZ (25).JPG'	Outros tipos de lesões'
MLSQ_57377_ESP (12).JPG'	Outros tipos de lesões'
MLSQ_57377_ESP (15).JPG'	Outros tipos de lesões'
MLSQ_57377_ESP (18).JPG'	Outros tipos de lesões'
MLSQ_5745377_ESP (19).JPG'	Outros tipos de lesões'
MLSQ_57377_ESP (22).JPG'	Outros tipos de lesões'
MLSQ_57377_ESP (23).JPG'	Outros tipos de lesões'
MLSQ_57377_ESP (5).JPG'	Outros tipos de lesões'
MCA_36348_PDT (12).JPG'	Outros tipos de lesões'
MCA_36348_PDT (20).JPG'	Outros tipos de lesões'
MCA_36348_PDT (21).JPG'	Outros tipos de lesões'
MCA_3688348_PDT (25).JPG'	Outros tipos de lesões'
MLF_83729_CEC (4).JPG'	Lesões de leishmaniose'
NFR_79850_PDT (5).JPG'	Outros tipos de lesões'
NFR_79850_PDT (7).JPG'	Outros tipos de lesões'
OSG_86518_IVC (17).JPG'	Outros tipos de lesões'
OSG_86518_IVC (21).JPG'	Outros tipos de lesões'
OSG_86518_IVC (3).JPG'	Outros tipos de lesões'
OSG_86518_IVC (5).JPG'	Outros tipos de lesões'
OSSG_83978_CBM (2).JPG'	Outros tipos de lesões'
OSSG_83978_CBM (6).JPG'	Outros tipos de lesões'
OSSG_83978_CBM (7).JPG'	Outros tipos de lesões'
OSSG_83978_CBM (8).JPG'	Outros tipos de lesões'
PMV_76119_CAT (4).JPG'	Outros tipos de lesões'
PMV_76119_CAT (7).JPG'	Outros tipos de lesões'
RCMS_85120_PDT (11).JPG'	Outros tipos de lesões'
RCMS_85120_PDT (5).JPG'	Lesões de leishmaniose'
RCMS_85120_PDT (9).JPG'	Outros tipos de lesões'
RFS_86219_LED (1).JPG'	Outros tipos de lesões'
RNMS_84727_LIP (1).JPG'	Outros tipos de lesões'
RNMS_84727_LIP (6).JPG'	Outros tipos de lesões'
RNMS_84727_LIP (8).JPG'	Outros tipos de lesões'
RBV_90076_LIP (10).JPG'	Lesões de leishmaniose'
RBV_90076_LIP (3).JPG'	Outros tipos de lesões'
RBV_90076_LIP (6).JPG'	Outros tipos de lesões'

RBR_88761_PDT (36).JPG'	Outros tipos de lesões'
RBR_88761_PDT (38).JPG'	Outros tipos de lesões'
RBR_88761_PDT (73).JPG'	Outros tipos de lesões'
RBR_88761_PDT (41).JPG'	Outros tipos de lesões'
RBR_88761_PDT (70).JPG'	Outros tipos de lesões'
RRLS_30850_LNF (3).JPG'	Outros tipos de lesões'
RRLS_30850_LNF (6).JPG'	Outros tipos de lesões'
TSS_81517_IVC (3).JPG'	Outros tipos de lesões'
URCS_89765_TIC (5).JPG'	Outros tipos de lesões'
URCS_89765_TIC (9).JPG'	Outros tipos de lesões'
VAL_88190_PCM (5).JPG'	Outros tipos de lesões'

SIMULAÇÃO 2

ID Photo	Predição do AlexNet
AFC_85802_LC (10).JPG'	Lesões de leishmaniose'
AFC_85802_LC (12).JPG'	Lesões de leishmaniose'
AFC_85802_LC (22).JPG'	Lesões de leishmaniose'
AFC_85802_LC (25).JPG'	Lesões de leishmaniose'
AFC_85802_LC (26).JPG'	Lesões de leishmaniose'
AFC_85802_LC (36).JPG'	Lesões de leishmaniose'
AFC_85802_LC (37).JPG'	Lesões de leishmaniose'
AFC_85802_LC (42).JPG'	Lesões de leishmaniose'
AFC_85802_LC (50).JPG'	Lesões de leishmaniose'
AFC_85802_LC (9).JPG'	Lesões de leishmaniose'
APN_67956_LC (2).JPG'	Lesões de leishmaniose'
APN_67956_LC (4).JPG'	Lesões de leishmaniose'
APN_67956_LC (6).JPG'	Lesões de leishmaniose'
ACL_8643710_LC (7).JPG'	Lesões de leishmaniose'
ACMB_78159_LC (14).JPG'	Lesões de leishmaniose'
ACMB_78159_LC (20).JPG'	Lesões de leishmaniose'
ACMB_78159_LC (3).JPG'	Lesões de leishmaniose'
AMCJ_8595_LC (13).JPG'	Lesões de leishmaniose'
AMCJ_8595_LC (5).JPG'	Lesões de leishmaniose'
AMCJ_8595_LC (7).JPG'	Lesões de leishmaniose'
AMC_17794_LC (14).JPG'	Lesões de leishmaniose'
AMC_17794_LC (20).JPG'	Lesões de leishmaniose'
AMC_17794_LC (22).JPG'	Lesões de leishmaniose'
AMC_1776194_LC (29).JPG'	Lesões de leishmaniose'
ARS_86922_LC (12).JPG'	Lesões de leishmaniose'
ARS_86922_LC (13).JPG'	Lesões de leishmaniose'
ARS_86922_LC2 (9).JPG'	Lesões de leishmaniose'
ADL_37588_LC (2).JPG'	Lesões de leishmaniose'
ASS_80302_LC (4).JPG'	Lesões de leishmaniose'
ASS_80302_LC (6).JPG'	Lesões de leishmaniose'
APS_88312_LC (1).JPG'	Lesões de leishmaniose'
APS_88312_LC (10).JPG'	Lesões de leishmaniose'
APS_88312_LC (16).JPG'	Lesões de leishmaniose'
APS_88312_LC (19).JPG'	Lesões de leishmaniose'
APS_88312_LC(25).JPG'	Lesões de leishmaniose'
APS_88312_LC (5).JPG'	Lesões de leishmaniose'
AS-59419_LC (2).JPG'	Lesões de leishmaniose'
AS-59419_LC (5).JPG'	Lesões de leishmaniose'
AS-59419_LC (8).JPG'	Lesões de leishmaniose'
ACRF_86823_LC (15).JPG'	Lesões de leishmaniose'
ACRF_86823_LC (19).JPG'	Lesões de leishmaniose'
ACRF_86823_LC (27).JPG'	Lesões de leishmaniose'

BON_84103_LC (7).JPG'	Lesões de leishmaniose'
BON_84103_LC (8).JPG'	Lesões de leishmaniose'
BEMS_81922_LC (2).JPG'	Lesões de leishmaniose'
CJR_84455_LC (14).JPG'	Lesões de leishmaniose'
CJR_8455_LC (17).JPG'	Lesões de leishmaniose'
CJR_84455_LC (19).JPG'	Lesões de leishmaniose'
CJR_84455_LC (25).JPG'	Lesões de leishmaniose'
CCS_85871_LC (10).JPG'	Lesões de leishmaniose'
CSL_86726_LC (14).JPG'	Lesões de leishmaniose'
CSL_86726_LC (3).JPG'	Lesões de leishmaniose'
CJSS_80496_LC (1).JPG'	Lesões de leishmaniose'
CTG_86134_LC (1).JPG'	Lesões de leishmaniose'
DAAC_86670_LC (2).JPG'	Lesões de leishmaniose'
DAAC_86670_LC (5).JPG'	Lesões de leishmaniose'
DOP_0029_LC (6).JPG'	Lesões de leishmaniose'
DOP_0029_LC (7).JPG'	Lesões de leishmaniose'
DOP_0029_LC (8).JPG'	Lesões de leishmaniose'
DOP_0029_LC (12).JPG'	Lesões de leishmaniose'
DOP_0029_LC (14).JPG'	Lesões de leishmaniose'
DEPS_88895_LC (6).JPG'	Lesões de leishmaniose'
DEPS_88895_LC (7).JPG'	Lesões de leishmaniose'
DSR_84714_LC (10).JPG'	Lesões de leishmaniose'
ERR_84688_LC (11).JPG'	Lesões de leishmaniose'
ERR_84688_LC (12).JPG'	Lesões de leishmaniose'
ERR_84688_LC (3).JPG'	Lesões de leishmaniose'
ERR_84688_LC (5).JPG'	Lesões de leishmaniose'
ERR_84688_LC (7).JPG'	Lesões de leishmaniose'
EFC_85786_LC (26).JPG'	Lesões de leishmaniose'
EFC_85786_LC (27).JPG'	Lesões de leishmaniose'
EFC_85786_LC (28).JPG'	Lesões de leishmaniose'
EFC_85786_LC (29).JPG'	Lesões de leishmaniose'
EFC_85786_LC (4).JPG'	Lesões de leishmaniose'
EFC_85786_LC (5).JPG'	Lesões de leishmaniose'
EFC_85786_LC (6).JPG'	Lesões de leishmaniose'
ESJ_84060_LC (15).JPG'	Lesões de leishmaniose'
ESJ_84060_LC (18).JPG'	Lesões de leishmaniose'
ESJ_84060_LC (20).JPG'	Lesões de leishmaniose'
EOS_84813_LC (13).JPG'	Lesões de leishmaniose'
ERZ_88753_LC (1).JPG'	Lesões de leishmaniose'
ERZ_88753_LC (5).JPG'	Lesões de leishmaniose'
ES_84182_LC (10).JPG'	Lesões de leishmaniose'
ES_84182_LC (12).JPG'	Lesões de leishmaniose'
ES_84182_LC (16).JPG'	Lesões de leishmaniose'
ES_84182_LC (24).JPG'	Lesões de leishmaniose'

ES_84182_LC (4).JPG'	Lesões de leishmaniose'
ES_84182_LC (7).JPG'	Lesões de leishmaniose'
EPC_85132_LC (1).JPG'	Lesões de leishmaniose'
FSMA_84484_LC (1).JPG'	Lesões de leishmaniose'
FSMA_84484_LC (2).JPG'	Lesões de leishmaniose'
FSMA_84484_LC (7).JPG'	Lesões de leishmaniose'
FMS_8467326_LC (12).JPG'	Lesões de leishmaniose'
FMS_84326_LC (25).JPG'	Lesões de leishmaniose'
FMS_84326_LC (3).JPG'	Lesões de leishmaniose'
FMS_84326_LC (30).JPG'	Lesões de leishmaniose'
FB_88089_LC (1).JPG'	Lesões de leishmaniose'
FB_88089_LC (4).JPG'	Lesões de leishmaniose'
FB_88089_LC (5).JPG'	Lesões de leishmaniose'
FMB_LC_85484 (19).JPG'	Lesões de leishmaniose'
FMB_LC_85484 (22).JPG'	Lesões de leishmaniose'
FMB_LC_85484 (6).JPG'	Lesões de leishmaniose'
FFSS_83627_LC (18).JPG'	Lesões de leishmaniose'
FFSS_83627_LC (4).JPG'	Lesões de leishmaniose'
FMG_86975_LC (15).JPG'	Lesões de leishmaniose'
FMG_86975_LC (20).JPG'	Lesões de leishmaniose'
FMG_86975_LC (22).JPG'	Outros tipos de lesões'
FMG_86975_LC (3).JPG'	Lesões de leishmaniose'
FMG_86975_LC (9).JPG'	Lesões de leishmaniose'
FEV_84692_LC (2).JPG'	Lesões de leishmaniose'
FEV_84692_LC (3).JPG'	Lesões de leishmaniose'
FEG_86211_LC (4).JPG'	Lesões de leishmaniose'
FEG_86211_LC (6).JPG'	Lesões de leishmaniose'
FEG_86211_LC (7).JPG'	Lesões de leishmaniose'
FLB_85985_LC (1).JPG'	Lesões de leishmaniose'
FLB_85985_LC (15).JPG'	Lesões de leishmaniose'
FLB_85985_LC (16).JPG'	Lesões de leishmaniose'
FLB_85985_LC (18).JPG'	Lesões de leishmaniose'
FLB_85985_LC (22).JPG'	Lesões de leishmaniose'
FLB_85985_LC (26).JPG'	Lesões de leishmaniose'
FMG_86975_LC (5).JPG'	Lesões de leishmaniose'
GMM_85697_LC (16).JPG'	Lesões de leishmaniose'
GMM_85697_LC(17).JPG'	Lesões de leishmaniose'
GMM_85697_LC (19).JPG'	Lesões de leishmaniose'
GMM_85697_LC (26).JPG'	Lesões de leishmaniose'
GMM_8533697_LC (4).JPG'	Lesões de leishmaniose'
GMM_8533697_LC (8).JPG'	Lesões de leishmaniose'
GLS_86649_LC (2).JPG'	Lesões de leishmaniose'
GAB_84015_LC (12).JPG'	Lesões de leishmaniose'
GAB_84015_LC (13).JPG'	Lesões de leishmaniose'

GAB_84015_LC (15).JPG'	Lesões de leishmaniose'
GAB_84015_LC (6).JPG'	Lesões de leishmaniose'
GAB_84015_LC (7).JPG'	Lesões de leishmaniose'
GAB_84015_LC (9).JPG'	Lesões de leishmaniose'
GPRO_79658_LC (2).JPG'	Lesões de leishmaniose'
GPRO_79658_LC (5).JPG'	Lesões de leishmaniose'
GFO_85492_LC (15).JPG'	Lesões de leishmaniose'
GFO_85492_LC (7).JPG'	Lesões de leishmaniose'
GFO_85492_LC (9).JPG'	Lesões de leishmaniose'
GSL_89566_LC (1).JPG'	Lesões de leishmaniose'
GSL_89566_LC (10).JPG'	Lesões de leishmaniose'
GSL_89566_LC (19).JPG'	Lesões de leishmaniose'
GSL_89566_LC (4).JPG'	Lesões de leishmaniose'
GLS_86595_LC (14).JPG'	Lesões de leishmaniose'
GLS_86595_LC (17).JPG'	Lesões de leishmaniose'
GLS_86595_LC (18).JPG'	Lesões de leishmaniose'
GLS_86595_LC (5).JPG'	Lesões de leishmaniose'
GLS_86595_LC (6).JPG'	Lesões de leishmaniose'
HVD_85328_LC (3).JPG'	Lesões de leishmaniose'
HIMG_28137_LC (12).JPG'	Lesões de leishmaniose'
HIMG_28137_LC (17).JPG'	Lesões de leishmaniose'
HIMG_28137_LC (18).JPG'	Lesões de leishmaniose'
HIMG_28137_LC (19).JPG'	Lesões de leishmaniose'
HIMG_28137_LC (2).JPG'	Lesões de leishmaniose'
HIMG_28137_LC (4).JPG'	Lesões de leishmaniose'
HIMG_28137_LC (7).JPG'	Lesões de leishmaniose'
HVLR_85882_LC (8).JPG'	Lesões de leishmaniose'
ISO_88320_LC (1).JPG'	Lesões de leishmaniose'
ISO_88320_LC (3).JPG'	Lesões de leishmaniose'
ISO_88320_LC (8).JPG'	Lesões de leishmaniose'
JDC_88812_LC (11).JPG'	Lesões de leishmaniose'
JDC_88812_LC (14).JPG'	Lesões de leishmaniose'
JDC_88812_LC2 (6).JPG'	Lesões de leishmaniose'
JVA_85112_LC (5).JPG'	Lesões de leishmaniose'
JGS_88853_LC (3).JPG'	Lesões de leishmaniose'
JGS_88853_LC (9).JPG'	Lesões de leishmaniose'
JCSC_84455_LC (20).JPG'	Outros tipos de lesões'
JSVL_280_LC (3).JPG'	Lesões de leishmaniose'
JSVL_280_LC (7).JPG'	Lesões de leishmaniose'
JMN_88647_LC (10).JPG'	Lesões de leishmaniose'
JMN_88647_LC (11).JPG'	Lesões de leishmaniose'
JMN_88647_LC (15).JPG'	Lesões de leishmaniose'
JMN_88647_LC (17).JPG'	Lesões de leishmaniose'
JRS_86521_LC (14).JPG'	Lesões de leishmaniose'

JRS_86521_LC (6).JPG'	Lesões de leishmaniose'
JBLB_84077_LC (2).JPG'	Lesões de leishmaniose'
JFFL_83861_LC (2).JPG'	Lesões de leishmaniose'
JFFL_83861_LC (5).JPG'	Lesões de leishmaniose'
JFFL_83861_LC (7).JPG'	Lesões de leishmaniose'
JLBD_84395_LC (13).JPG'	Lesões de leishmaniose'
JLBD_84395_LC (14).JPG'	Lesões de leishmaniose'
JPCF_86700_LC (3).JPG'	Lesões de leishmaniose'
JPCF_86700_LC (9).JPG'	Lesões de leishmaniose'
JVBC_86562_LC (4).JPG'	Lesões de leishmaniose'
JVBC_86562_LC (5).JPG'	Lesões de leishmaniose'
JCB_80150_LC (2).JPG'	Lesões de leishmaniose'
JCB_80150_LC (4).JPG'	Lesões de leishmaniose'
JFS_86426_LC (10).JPG'	Lesões de leishmaniose'
JFS_86426_LC (16).JPG'	Lesões de leishmaniose'
JFS_86426_LC (6).JPG'	Lesões de leishmaniose'
JCM_84530_LC (2).JPG'	Lesões de leishmaniose'
JCM_84530_LC(6).JPG'	Lesões de leishmaniose'
JECG_75788_LC (6).JPG'	Lesões de leishmaniose'
JECG_75788_LC (9).JPG'	Lesões de leishmaniose'
JONF_86371_LC (1).JPG'	Lesões de leishmaniose'
JRBS_78549_LC (1).JPG'	Lesões de leishmaniose'
JRC_81129_LC (3).JPG'	Lesões de leishmaniose'
JRC_81129_LC (6).JPG'	Lesões de leishmaniose'
JRC_81129_LC (8).JPG'	Lesões de leishmaniose'
JAS_84644_LC (1).JPG'	Lesões de leishmaniose'
JAS_84644_LC (8).JPG'	Lesões de leishmaniose'
JJS_72328_LC (5).JPG'	Lesões de leishmaniose'
JMB_84766_LC (10).JPG'	Lesões de leishmaniose'
JMB_84766_LC (2).JPG'	Lesões de leishmaniose'
JMB_84766_LC (4).JPG'	Lesões de leishmaniose'
JMB_84766_LC (7).JPG'	Lesões de leishmaniose'
JRC_90334_LC (11).JPG'	Lesões de leishmaniose'
JHF_05676_LC (2).JPG'	Lesões de leishmaniose'
LTM_86226_LC (2).JPG'	Lesões de leishmaniose'
LJBC_84025_LC (10).JPG'	Lesões de leishmaniose'
LJBC_84025_LC (11).JPG'	Lesões de leishmaniose'
LJBC_84025_LC (4).JPG'	Lesões de leishmaniose'
LJBC_84025_LC (7).JPG'	Lesões de leishmaniose'
LJBC_84025_LC (8).JPG'	Lesões de leishmaniose'
LMBO_81741_LC (3).JPG'	Lesões de leishmaniose'
LGT_84989_LC (1).JPG'	Lesões de leishmaniose'
LGT_84989_LC (6).JPG'	Lesões de leishmaniose'
LFTLG_85336_LC (2).JPG'	Lesões de leishmaniose'

LFTLG_85336_LC (7).JPG'	Lesões de leishmaniose'
LFTLG_85336_LC (8).JPG'	Lesões de leishmaniose'
MCAS_84096_LC (4).JPG'	Lesões de leishmaniose'
MCAS_84096_LC (9).JPG'	Lesões de leishmaniose'
MAN_89041_LC (3).JPG'	Lesões de leishmaniose'
MAC_85920_LC (11).JPG'	Lesões de leishmaniose'
MAPB_86299_LC (8).JPG'	Lesões de leishmaniose'
MWMN_84438_LC (10).JPG'	Lesões de leishmaniose'
MWMN_84438_LC (11).JPG'	Lesões de leishmaniose'
MWMN_84438_LC (2).JPG'	Lesões de leishmaniose'
MWMN_84438_LC (4).JPG'	Lesões de leishmaniose'
MAC_84826_LC (1).JPG'	Lesões de leishmaniose'
MAC_84826_LC (10).JPG'	Lesões de leishmaniose'
MAC_84826_LC (12).JPG'	Lesões de leishmaniose'
MAC_84826_LC (9).JPG'	Lesões de leishmaniose'
MVM_82481_LC (1).JPG'	Lesões de leishmaniose'
MVCS_82043_LC (3).JPG'	Lesões de leishmaniose'
MBBR_85993_LC (8).JPG'	Lesões de leishmaniose'
MCAR_85976_LC (6).JPG'	Lesões de leishmaniose'
MCAR_85976_LC (7).JPG'	Lesões de leishmaniose'
MCPS_81271_LC (3).JPG'	Lesões de leishmaniose'
MCPS_81271_LC (6).JPG'	Lesões de leishmaniose'
MHCS_85704_LC (11).JPG'	Lesões de leishmaniose'
MHCS_85704_LC (7).JPG'	Lesões de leishmaniose'
MMF_85778_LC (14).JPG'	Lesões de leishmaniose'
MMF_85778_LC (17).JPG'	Lesões de leishmaniose'
MMLS_84879_LC (5).JPG'	Lesões de leishmaniose'
MRSS_85199_LC (8).JPG'	Lesões de leishmaniose'
MSBS_82587_LC (2).JPG'	Lesões de leishmaniose'
MTJA_56136_LC (10).JPG'	Lesões de leishmaniose'
MTJA_56136_LC (12).JPG'	Lesões de leishmaniose'
MTJA_56136_LC (13).JPG'	Lesões de leishmaniose'
MTJA_56136_LC (18).JPG'	Lesões de leishmaniose'
MTJA_56136_LC (2).JPG'	Lesões de leishmaniose'
MATB_26499_LC (6).JPG'	Lesões de leishmaniose'
MATB_26499_LC (7).JPG'	Lesões de leishmaniose'
MAD_86106_LC (1).JPG'	Lesões de leishmaniose'
MAD_86106_LC (2).JPG'	Lesões de leishmaniose'
MAD_86106_LC (3).JPG'	Lesões de leishmaniose'
MAD_86106_LC (8).JPG'	Lesões de leishmaniose'
MABC_84017_LC (11).JPG'	Lesões de leishmaniose'
MABC_84017_LC (3).JPG'	Lesões de leishmaniose'
MABC_84017_LC (8).JPG'	Lesões de leishmaniose'
MBJ_70782_LC (5).JPG'	Lesões de leishmaniose'

MOA_85592_LC (27).JPG'	Lesões de leishmaniose'
MOA_85592_LC (42).JPG'	Lesões de leishmaniose'
MOA_85592_LC (45).JPG'	Lesões de leishmaniose'
MOA_85592_LC (49).JPG'	Lesões de leishmaniose'
MOA_88322_LC (5).JPG'	Lesões de leishmaniose'
MPS_88873_LC (15).JPG'	Lesões de leishmaniose'
MPS_88873_LC (16).JPG'	Lesões de leishmaniose'
MPS_88873_LC (2).JPG'	Lesões de leishmaniose'
MPS_88873_LC (25).JPG'	Lesões de leishmaniose'
MSB_88173_LC (14).JPG'	Lesões de leishmaniose'
MSB_88173_LC (3).JPG'	Lesões de leishmaniose'
MLM_86568_LC (5).JPG'	Lesões de leishmaniose'
NBS_84628_LC (2).JPG'	Lesões de leishmaniose'
NCA_20888_LC (1).JPG'	Lesões de leishmaniose'
NCA_20888_LC (2).JPG'	Lesões de leishmaniose'
NSA_84016_LC (10).JPG'	Lesões de leishmaniose'
NSA_84016_LC (16).JPG'	Lesões de leishmaniose'
NSA_84016_LC (17).JPG'	Lesões de leishmaniose'
NSA_84016_LC (18).JPG'	Lesões de leishmaniose'
NSA_84016_LC (3).JPG'	Lesões de leishmaniose'
NSA_84016_LC (4).JPG'	Lesões de leishmaniose'
NSA_84016_LC (5).JPG'	Lesões de leishmaniose'
NSA_84016_LC (7).JPG'	Lesões de leishmaniose'
NRR_86696_LC (3).JPG'	Lesões de leishmaniose'
NRR_86696_LC(5).JPG'	Lesões de leishmaniose'
OLL_89703_LC (8).JPG'	Lesões de leishmaniose'
OSL_27557_LC (1).JPG'	Lesões de leishmaniose'
PKMLC_84031_LC (11).JPG'	Lesões de leishmaniose'
PKMLC_84031_LC (12).JPG'	Lesões de leishmaniose'
PKMLC_84031_LC (17).JPG'	Lesões de leishmaniose'
PKMLC_84031_LC (18).JPG'	Lesões de leishmaniose'
PKMLC_84031_LC (2).JPG'	Lesões de leishmaniose'
PKMLC_84031_LC (5).JPG'	Lesões de leishmaniose'
PHVCSC_84044_LC (1).JPG'	Lesões de leishmaniose'
PHVCSC_84044_LC (15).JPG'	Lesões de leishmaniose'
PHVCSC_84044_LC (18).JPG'	Lesões de leishmaniose'
PHVCSC_84044_LC (21).JPG'	Lesões de leishmaniose'
PHVCSC_84044_LC (22).JPG'	Lesões de leishmaniose'
PHVCSC_84044_LC (23).JPG'	Lesões de leishmaniose'
PHVCSC_84044_LC (24).JPG'	Lesões de leishmaniose'
PJMM_90269_LC (3).JPG'	Lesões de leishmaniose'
PJMM_90269_LC (4).JPG'	Lesões de leishmaniose'
PJMM_90269_LC (6).JPG'	Lesões de leishmaniose'
RBS_86925_LC (1).JPG'	Lesões de leishmaniose'

RBS_86925_LC (12).JPG'	Lesões de leishmaniose'
RBS_86925_LC (13).JPG'	Lesões de leishmaniose'
RBS_86925_LC (2).JPG'	Lesões de leishmaniose'
RSS_84951_LC (5).JPG'	Lesões de leishmaniose'
RSS_84951_LC (7).JPG'	Lesões de leishmaniose'
RSS_84951_LC (7).JPG' (1).JPG'	Lesões de leishmaniose'
RSS_84951_LC (7).JPG' (12).JPG'	Lesões de leishmaniose'
RSS_84951_LC (7).JPG' (14).JPG'	Lesões de leishmaniose'
RSS_84951_LC (7).JPG' (16).JPG'	Lesões de leishmaniose'
RSS_84951_LC (7).JPG' (19).JPG'	Lesões de leishmaniose'
RSS_84951_LC (7).JPG' (20).JPG'	Lesões de leishmaniose'
RSS_84951_LC (7).JPG' (21).JPG'	Lesões de leishmaniose'
RSS_84951_LC (7).JPG' (23).JPG'	Lesões de leishmaniose'
RSS_84951_LC (7).JPG' (7).JPG'	Lesões de leishmaniose'
RPA_87608_LC (15).JPG'	Lesões de leishmaniose'
RPA_87608_LC (9).JPG'	Lesões de leishmaniose'
RLS_80973_LC (1).JPG'	Lesões de leishmaniose'
RLS_80973_LC (11).jpg'	Lesões de leishmaniose'
RLS_80973_LC (18).JPG'	Lesões de leishmaniose'
RLS_80973_LC (19).JPG'	Lesões de leishmaniose'
RLS_80973_LC (2).JPG'	Lesões de leishmaniose'
RLS_80973_LC (26).JPG'	Lesões de leishmaniose'
RLS_80973_LC (27).JPG'	Lesões de leishmaniose'
RLS_80973_LC (39).JPG'	Lesões de leishmaniose'
RLS_80973_LC (8).JPG'	Lesões de leishmaniose'
SBD_85168_LC (10).JPG'	Lesões de leishmaniose'
SBD_85168_LC (2).JPG'	Lesões de leishmaniose'
SBD_85168_LC (8).JPG'	Lesões de leishmaniose'
SRSF_86531_LC (1).JPG'	Lesões de leishmaniose'
SSRL_84717_LC (2).JPG'	Lesões de leishmaniose'
STSP_22520_LC (2).JPG'	Outros tipos de lesões'
STSP_22520_LC (6).JPG'	Lesões de leishmaniose'
TPV_84919_LC (6).JPG'	Lesões de leishmaniose'
TPV_84919_LC (7).JPG'	Lesões de leishmaniose'
VJN_85150_LC (18).JPG'	Lesões de leishmaniose'
VJN_85150_LC (20).JPG'	Lesões de leishmaniose'
VJN_85150_LC (21).JPG'	Lesões de leishmaniose'
VJN_85150_LC(25).JPG'	Lesões de leishmaniose'
VAN_90245_LC (3).JPG'	Lesões de leishmaniose'
VAN_90245_LC (6).JPG'	Lesões de leishmaniose'
VSO_18786_LC (4).JPG'	Lesões de leishmaniose'
VSO_18786_LC (16).JPG'	Lesões de leishmaniose'
VDS_88810_LC (1).JPG'	Lesões de leishmaniose'
VDS_88810_LC (4).JPG'	Lesões de leishmaniose'

WASL_85534_LC (1).JPG'	Lesões de leishmaniose'
WASL_85534_LC (5).JPG'	Lesões de leishmaniose'
WASL_85534_LC (7).JPG'	Lesões de leishmaniose'
WBS_78712_LC (10).JPG'	Lesões de leishmaniose'
WBS_78712_LC (5).JPG'	Lesões de leishmaniose'
WBS_78712_LC (6).JPG'	Lesões de leishmaniose'
WBS_78712_LC (7).JPG'	Lesões de leishmaniose'
MLF_83529_CEC (1).JPG'	Outros tipos de lesões'
MLF_83529_CEC (3).JPG'	Outros tipos de lesões'
MLF_83529_CEC (7).JPG'	Outros tipos de lesões'
ASM_36829_CEC (12).JPG'	Outros tipos de lesões'
ASM_36829_CEC (13).JPG'	Outros tipos de lesões'
ASM_36829_CEC (4).JPG'	Outros tipos de lesões'
ADE_85056_ECZ (2).JPG'	Outros tipos de lesões'
ABS_85306_IVC (12).JPG'	Outros tipos de lesões'
ABS_85306_IVC (3).JPG'	Outros tipos de lesões'
ABS_85306_IVC (8).JPG'	Outros tipos de lesões'
AJB_86684_IVC (10).JPG'	Outros tipos de lesões'
AJB_86684_IVC (7).JPG'	Outros tipos de lesões'
CNM_85338_HAN (14).JPG'	Outros tipos de lesões'
CNM_85338_HAN (19).JPG'	Outros tipos de lesões'
CNM_85338_HAN (4).JPG'	Outros tipos de lesões'
CLS_35167_VSL (2).JPG'	Outros tipos de lesões'
CLS_35167_VSL (3).JPG'	Outros tipos de lesões'
CLS_35167_VSL(8).JPG'	Outros tipos de lesões'
DSC_47487_LFC (1).JPG'	Outros tipos de lesões'
DSC_47487_LFC (8).JPG'	Outros tipos de lesões'
EAM_89659_HAN (13).JPG'	Outros tipos de lesões'
EAM_89659_HAN (14).JPG'	Lesões de leishmaniose'
EAM_89659_HAN (19).JPG'	Outros tipos de lesões'
EAM_89659_HAN (29).JPG'	Outros tipos de lesões'
EAM_89659_HAN (31).JPG'	Lesões de leishmaniose'
EAM_89659_HAN (6).JPG'	Outros tipos de lesões'
EAM_89659_HAN (7).JPG'	Outros tipos de lesões'
EAM_89659_HAN (8).JPG'	Outros tipos de lesões'
ECC_88279_EPT (13).JPG'	Outros tipos de lesões'
ECC_88279_EPT (2).JPG'	Outros tipos de lesões'
EMN_11153_PDT (11).JPG'	Lesões de leishmaniose'
EDL_85289_EPF (1).JPG'	Outros tipos de lesões'
EDL_85289_EPF (2).JPG'	Outros tipos de lesões'
EDL_85289_EPF (4).JPG'	Lesões de leishmaniose'
EOGM_88992_RSC (1).JPG'	Outros tipos de lesões'
EBN_85447_CBC (1).JPG'	Lesões de leishmaniose'
EBN_85447_CBC (3).JPG'	Lesões de leishmaniose'

EBN_85447_CBC (6).JPG'	Outros tipos de lesões'
GAN_49596_IVC (1).JPG'	Outros tipos de lesões'
GAN_49596_IVC (11).JPG'	Outros tipos de lesões'
GAN_49596_IVC (23).JPG'	Outros tipos de lesões'
GAN_49596_IVC (5).JPG'	Outros tipos de lesões'
GAN_49596_IVC (6).JPG'	Outros tipos de lesões'
GAN_49596_IVC (7).JPG'	Outros tipos de lesões'
GSN_88162_IMP (10).JPG'	Outros tipos de lesões'
GSN_88162_IMP (3).JPG'	Outros tipos de lesões'
IMM_86646_SIT (12).JPG'	Outros tipos de lesões'
IMM_86646_SIT (3).JPG'	Outros tipos de lesões'
IMM_86646_SIT (6).JPG'	Outros tipos de lesões'
IMM_86646_SIT (9).JPG'	Outros tipos de lesões'
INS_90288_CBM (2).JPG'	Lesões de leishmaniose'
INS_90288_CBM (21).JPG'	Outros tipos de lesões'
INS_90288_CBM (25).JPG'	Outros tipos de lesões'
INS_90288_CBM (27).JPG'	Outros tipos de lesões'
INS_90288_CBM (29).JPG'	Outros tipos de lesões'
INS_90288_CBM (31).JPG'	Outros tipos de lesões'
INS_90288_CBM (36).JPG'	Outros tipos de lesões'
INS_90288_CBM (37).JPG'	Outros tipos de lesões'
INS_90288_CBM (39).JPG'	Outros tipos de lesões'
INS_90288_CBM (7).JPG'	Outros tipos de lesões'
INS_90288_CBM (8).JPG'	Outros tipos de lesões'
JAF_86533_ECT (1).JPG'	Outros tipos de lesões'
JAF_86533_ECT (17).JPG'	Outros tipos de lesões'
JAF_86533_ECT (29).JPG'	Outros tipos de lesões'
JFA_88620_LSC (15).JPG'	Outros tipos de lesões'
JCT_86261_CBC (4).JPG'	Outros tipos de lesões'
JLGL_81738_PDT (1).JPG'	Outros tipos de lesões'
JRR_55758_PCT (2).JPG'	Outros tipos de lesões'
JRR_55758_PCT (3).JPG'	Outros tipos de lesões'
LCSP_88140_ECT (34).JPG'	Outros tipos de lesões'
LCSP_88140_ECT (40).JPG'	Outros tipos de lesões'
LTF_86184_HAN (2).JPG'	Outros tipos de lesões'
LAC_84233_PDT (1).JPG'	Outros tipos de lesões'
LAC_84233_PDT (11).JPG'	Outros tipos de lesões'
LAC_84233_PDT (3).JPG'	Outros tipos de lesões'
LIA_64143_PDT (2).JPG'	Lesões de leishmaniose'
MMA_88125_IVC (5).JPG'	Outros tipos de lesões'
MPV_26799_CBC (1).JPG'	Outros tipos de lesões'
MPV_26799_CBC (6).JPG'	Lesões de leishmaniose'
MRA_88204_IVC (2).JPG'	Outros tipos de lesões'
MRA_88204_IVC (6).JPG'	Outros tipos de lesões'

MFMS_26609_ECT (13).JPG'	Outros tipos de lesões'
MFMS_26609_ECT (14).JPG'	Outros tipos de lesões'
MFMS_26609_ECT (4).JPG'	Lesões de leishmaniose'
MFMS_26609_ECT (5).JPG'	Outros tipos de lesões'
MFRS_88083_ECZ (27).JPG'	Lesões de leishmaniose'
MFRS_88083_ECZ (28).JPG'	Outros tipos de lesões'
MLSQ_57377_ESP (14).JPG'	Outros tipos de lesões'
MLSQ_57377_ESP (17).JPG'	Outros tipos de lesões'
MLSQ_57377_ESP (2).JPG'	Lesões de leishmaniose'
MLSQ_57377_ESP (3).JPG'	Lesões de leishmaniose'
MLSQ_57377_ESP (8).JPG'	Outros tipos de lesões'
MCA_36348_PDT (17).JPG'	Outros tipos de lesões'
MCA_36348_PDT (20).JPG'	Outros tipos de lesões'
MCA_36348_PDT (22).JPG'	Outros tipos de lesões'
MCA_36348_PDT (23).JPG'	Outros tipos de lesões'
MLF_83529_CEC (2).jpg'	Outros tipos de lesões'
OSG_86518_IVC (14).JPG'	Outros tipos de lesões'
OSG_86518_IVC (16).JPG'	Outros tipos de lesões'
OSG_86518_IVC (17).JPG'	Outros tipos de lesões'
OSG_86518_IVC (20).JPG'	Outros tipos de lesões'
OSG_86518_IVC (22).JPG'	Outros tipos de lesões'
OSSG_83978_CBM (1).JPG'	Outros tipos de lesões'
OSSG_83978_CBM (11).JPG'	Outros tipos de lesões'
OSSG_83978_CBM (7).JPG'	Outros tipos de lesões'
PRV_85063_CBC (10).JPG'	Outros tipos de lesões'
PMV_76819_CAT (4).JPG'	Lesões de leishmaniose'
PMV_76819_CAT (6).JPG'	Lesões de leishmaniose'
RCMS_85120_PDT (10).JPG'	Outros tipos de lesões'
RCMS_85120_PDT (13).JPG'	Outros tipos de lesões'
RCMS_85120_PDT (16).JPG'	Outros tipos de lesões'
RCMS_85120_PDT (22).JPG'	Outros tipos de lesões'
RCMS_85120_PDT (24).JPG'	Outros tipos de lesões'
RCMS_85120_PDT (25)j.JPG'	Outros tipos de lesões'
RCMS_85120_PDT (27).JPG'	Outros tipos de lesões'
RCMS_85120_PDT (33).JPG'	Lesões de leishmaniose'
RCMS_85120_PDT (9).JPG'	Outros tipos de lesões'
RFS_86719_LED (1).JPG'	Outros tipos de lesões'
RFS_86719_LED (11).JPG'	Outros tipos de lesões'
RFS_86719_LED (14).JPG'	Outros tipos de lesões'
RFS_86719_LED (4).JPG'	Outros tipos de lesões'
RFS_86719_LED (8).JPG'	Outros tipos de lesões'
RNMS_84727_LIP (1).JPG'	Lesões de leishmaniose'
RNMS_84727_LIP (2).JPG'	Lesões de leishmaniose'
RNMS_84727_LIP (5).JPG'	Outros tipos de lesões'

RBV_90076_LIP (3).JPG'	Lesões de leishmaniose'
RBV_90076_LIP (7).JPG'	Outros tipos de lesões'
RBR_88761_PDT (39).JPG'	Outros tipos de lesões'
RBR_88761_PDT (37).JPG'	Outros tipos de lesões'
RRLS_30850_LNF (1).JPG'	Outros tipos de lesões'
SRB_11396_EPT (2).JPG'	Outros tipos de lesões'
TSS_81617_IVC (3).JPG'	Outros tipos de lesões'
URCS_89765_TIC (5).JPG'	Outros tipos de lesões'
VAL_88190_PCM (6).JPG'	Outros tipos de lesões'

SIMULAÇÃO 3

ID Photo	Predição do AlexNet
AFC_85802_LC (1).JPG'	Lesões de leishmaniose'
AFC_85802_LC (13).JPG'	Lesões de leishmaniose'
AFC_85802_LC (16).JPG'	Lesões de leishmaniose'
AFC_85802_LC (29).JPG'	Lesões de leishmaniose'
AFC_85802_LC (33).JPG'	Lesões de leishmaniose'
AFC_85802_LC (41).JPG'	Lesões de leishmaniose'
AFC_85802_LC (44).JPG'	Lesões de leishmaniose'
AFC_85802_LC (45).JPG'	Lesões de leishmaniose'
AFC_85802_LC (52).JPG'	Lesões de leishmaniose'
APN_67956_LC (4).JPG'	Lesões de leishmaniose'
ACL_86710_LC (12).JPG'	Lesões de leishmaniose'
ACL_86710_LC (15).JPG'	Lesões de leishmaniose'
ACL_86710_LC (9).JPG'	Lesões de leishmaniose'
ACMB_78159_LC (12).JPG'	Lesões de leishmaniose'
ACMB_78159_LC (16).JPG'	Lesões de leishmaniose'
ACMB_78159_LC (18).JPG'	Lesões de leishmaniose'
ACMB_78159_LC (22).JPG'	Lesões de leishmaniose'
ACMB_78159_LC (7).JPG'	Lesões de leishmaniose'
AMCJ_8595_LC (17).JPG'	Lesões de leishmaniose'
AMCJ_8595_LC (18).JPG'	Lesões de leishmaniose'
AMCJ_8595_LC(22).JPG'	Lesões de leishmaniose'
AMCJ_8595_LC (8).JPG'	Lesões de leishmaniose'
AMC_17794_LC (10).JPG'	Lesões de leishmaniose'
AMC_17794_LC (15).JPG'	Lesões de leishmaniose'
AMC_17794_LC (19).JPG'	Lesões de leishmaniose'
AMC_17794_LC (25).JPG'	Lesões de leishmaniose'
AMC_17794_LC (26).JPG'	Lesões de leishmaniose'
AMC_17794_LC (9).JPG'	Lesões de leishmaniose'
ARS_86922_LC (10).JPG'	Lesões de leishmaniose'
ARS_86922_LC(9).JPG'	Lesões de leishmaniose'
ADL_37588_LC (1).JPG'	Lesões de leishmaniose'
ADL_37588_LC(5).JPG'	Lesões de leishmaniose'
ASS_80302_LC.JPG'	Lesões de leishmaniose'
APS_88312_LC (1).JPG'	Lesões de leishmaniose'
APS_88312_LC (11).JPG'	Lesões de leishmaniose'
APS_88312_LC (7).JPG'	Lesões de leishmaniose'
APS_88312_LC (8).JPG'	Lesões de leishmaniose'
APS_88312_LC (9).JPG'	Outros tipos de lesões'
AS-59419_LC (12).JPG'	Lesões de leishmaniose'
AS-59419_LC (3).JPG'	Lesões de leishmaniose'
AS-59419_LC (4).JPG'	Lesões de leishmaniose'
AS-59419_LC (6).JPG'	Lesões de leishmaniose'

ACRF_86823_LC (1).JPG'	Lesões de leishmaniose'
ACRF_86823_LC (15).JPG'	Lesões de leishmaniose'
ACRF_86823_LC (18).JPG'	Lesões de leishmaniose'
ACRF_86823_LC (20).JPG'	Lesões de leishmaniose'
ACRF_86823_LC (21).JPG'	Lesões de leishmaniose'
ACRF_86823_LC (22).JPG'	Lesões de leishmaniose'
ACRF_86823_LC (28).JPG'	Outros tipos de lesões'
ACRF_86823_LC(29).JPG'	Lesões de leishmaniose'
ACRF_86823_LC (30).JPG'	Lesões de leishmaniose'
BON_84103_LC (5).JPG'	Lesões de leishmaniose'
BON_84103_LC (7).JPG'	Lesões de leishmaniose'
BEMS_81922_LC (2).JPG'	Lesões de leishmaniose'
BOT_81948_LC (3).JPG'	Lesões de leishmaniose'
CC_85915_LC(12).JPG'	Lesões de leishmaniose'
CC_85915_LC (9).JPG'	Lesões de leishmaniose'
CJR_84455_LC (14).JPG'	Lesões de leishmaniose'
CJR_84455_LC (15).JPG'	Lesões de leishmaniose'
CJR_84455_LC (17).JPG'	Lesões de leishmaniose'
CJR_84455_LC (19).JPG'	Lesões de leishmaniose'
CENS-86698 (6).JPG'	Lesões de leishmaniose'
CCS_85871_LC (11).JPG'	Lesões de leishmaniose'
CCS_85871_LC(11).JPG'	Lesões de leishmaniose'
DAAC_86670_LC (1).JPG'	Lesões de leishmaniose'
DAAC_86670_LC (5).JPG'	Lesões de leishmaniose'
DOP_0829_LC (1).JPG'	Lesões de leishmaniose'
DOP_0829_LC (5).JPG'	Lesões de leishmaniose'
DOP_0829_LC (9).JPG'	Lesões de leishmaniose'
DOP_0829_LC (7).JPG'	Lesões de leishmaniose'
DEPS_88895_LC (6).JPG'	Lesões de leishmaniose'
DEPS_88895_LC (8).JPG'	Lesões de leishmaniose'
DSR_84714_LC (12).JPG'	Lesões de leishmaniose'
DSR_84714_LC (14).JPG'	Lesões de leishmaniose'
DSR_84714_LC (3).JPG'	Lesões de leishmaniose'
DSR_84714_LC (5).JPG'	Lesões de leishmaniose'
DSR_84714_LC (6).JPG'	Lesões de leishmaniose'
DSR_84714_LC (7).JPG'	Lesões de leishmaniose'
ERR_84688_LC (12).JPG'	Lesões de leishmaniose'
ERR_84688_LC (4).JPG'	Lesões de leishmaniose'
ERR_84688_LC (9).JPG'	Lesões de leishmaniose'
EFC_85786_LC (21).JPG'	Lesões de leishmaniose'
EFC_85786_LC (30).JPG'	Lesões de leishmaniose'
EFC_85786_LC (4).JPG'	Lesões de leishmaniose'
EFC_8586786_LC (6).JPG'	Lesões de leishmaniose'
ESJ_84060_LC (14).JPG'	Lesões de leishmaniose'

ESJ_84060_LC (20).JPG'	Lesões de leishmaniose'
ESB_79114_LC (4).JPG'	Lesões de leishmaniose'
EOS_84813_LC(16).JPG'	Lesões de leishmaniose'
EOS_84813_LC (17).JPG'	Lesões de leishmaniose'
EOS_84813_LC (6).JPG'	Lesões de leishmaniose'
EFO_82578_LC (3).JPG'	Lesões de leishmaniose'
ES_84682_LC (10).JPG'	Lesões de leishmaniose'
ES_84682_LC (13).JPG'	Lesões de leishmaniose'
ES_84682_LC (17).JPG'	Lesões de leishmaniose'
ES_84682_LC (19).JPG'	Lesões de leishmaniose'
ES_84682_LC (21).JPG'	Lesões de leishmaniose'
ES_84682_LC (22).JPG'	Lesões de leishmaniose'
ES_84682_LC (4).JPG'	Lesões de leishmaniose'
ES_84682_LC (6).JPG'	Lesões de leishmaniose'
ES_84682_LC (8).JPG'	Lesões de leishmaniose'
ES_84682_LC (9).JPG'	Lesões de leishmaniose'
EPC_85132_LC (15).JPG'	Lesões de leishmaniose'
EVSH_7892_LC (1).JPG'	Lesões de leishmaniose'
EVSH_7892_LC (10).JPG'	Lesões de leishmaniose'
EVSH_7892_LC (7).JPG'	Lesões de leishmaniose'
EVSH_7892_LC (8).JPG'	Lesões de leishmaniose'
FSMA_84484_LC(7).JPG'	Lesões de leishmaniose'
FSMA_84484_LC (8).JPG'	Lesões de leishmaniose'
FMS_84326_LC (12).JPG'	Lesões de leishmaniose'
FMS_84326_LC (22).JPG'	Lesões de leishmaniose'
FMS_84326_LC (26).JPG'	Lesões de leishmaniose'
FMS_84326_LC (31).JPG'	Lesões de leishmaniose'
FMS_84326_LC (9).JPG'	Lesões de leishmaniose'
FFSS_83627_LC (1).JPG'	Lesões de leishmaniose'
FFSS_83627_LC (10).JPG'	Lesões de leishmaniose'
FFSS_83627_LC (2).JPG'	Lesões de leishmaniose'
FMG_86975_LC (11).JPG'	Lesões de leishmaniose'
FMG_86975_LC (12).JPG'	Lesões de leishmaniose'
FMG_86975_LC (13).JPG'	Lesões de leishmaniose'
FMG_86975_LC (16).JPG'	Lesões de leishmaniose'
FMG_86975_LC (17).JPG'	Lesões de leishmaniose'
FMG_86975_LC (2).JPG'	Lesões de leishmaniose'
FMG_86975_LC (5).JPG'	Lesões de leishmaniose'
FEV_84692_LC (11).JPG'	Lesões de leishmaniose'
FEV_84692_LC (14).JPG'	Lesões de leishmaniose'
FEV_84692_LC (3).JPG'	Lesões de leishmaniose'
FEV_84692_LC (9).JPG'	Lesões de leishmaniose'
FLB_85985_LC (26).JPG'	Lesões de leishmaniose'
FLB_85985_LC (28).JPG'	Lesões de leishmaniose'

FMG_86975_LC (2).JPG'	Lesões de leishmaniose'
FMG_86975_LC (4).JPG'	Lesões de leishmaniose'
FMG_86975_LC (6).JPG'	Lesões de leishmaniose'
GMM_85697_LC (14).JPG'	Lesões de leishmaniose'
GMM_85697_LC (16).JPG'	Lesões de leishmaniose'
GMM_85697_LC (4).JPG'	Lesões de leishmaniose'
GBS_84619 (3).JPG'	Lesões de leishmaniose'
GLS_86649_LC (4).JPG'	Lesões de leishmaniose'
GAB_84015_LC (13).JPG'	Lesões de leishmaniose'
GPRO_79658_LC (2).JPG'	Lesões de leishmaniose'
GPRO_79658_LC (3).JPG'	Lesões de leishmaniose'
GPRO_79658_LC (7).JPG'	Lesões de leishmaniose'
GFO_85492_LC (12).JPG'	Lesões de leishmaniose'
GFO_85492_LC (17).JPG'	Lesões de leishmaniose'
GFO_85492_LC (18).JPG'	Lesões de leishmaniose'
GFO_85492_LC (3).JPG'	Lesões de leishmaniose'
GSL_89766_LC (12).JPG'	Lesões de leishmaniose'
GSL_89766_LC (14).JPG'	Lesões de leishmaniose'
GSL_89766_LC (16).JPG'	Lesões de leishmaniose'
GSL_89766_LC (20).JPG'	Lesões de leishmaniose'
GLS_86995_LC (4).JPG'	Lesões de leishmaniose'
HIMG_28137_LC (11).JPG'	Lesões de leishmaniose'
HIMG_28137_LC (14).JPG'	Lesões de leishmaniose'
HIMG_28137_LC (20).JPG'	Lesões de leishmaniose'
HIMG_28137_LC (3).JPG'	Lesões de leishmaniose'
HIMG_28137_LC (4).JPG'	Lesões de leishmaniose'
HIMG_28137_LC (8).JPG'	Lesões de leishmaniose'
HVLR_8582_LC (4).JPG'	Lesões de leishmaniose'
HVLR_8582_LC (6).JPG'	Lesões de leishmaniose'
IOSJ_81942_LC (2).JPG'	Lesões de leishmaniose'
IOSJ_81942_LC (3).JPG'	Lesões de leishmaniose'
ISO_88320_LC (3).JPG'	Lesões de leishmaniose'
ISO_88320_LC (5).JPG'	Lesões de leishmaniose'
ISO_88320_LC (8).JPG'	Lesões de leishmaniose'
JDC_88812_LC (13).JPG'	Lesões de leishmaniose'
JDC_88812_LC (5).JPG'	Lesões de leishmaniose'
JDN_64135_LC (6).JPG'	Lesões de leishmaniose'
JCSC_84455_LC (11).JPG'	Lesões de leishmaniose'
JCSC_84455_LC (15).JPG'	Lesões de leishmaniose'
JCSC_84455_LC (17).JPG'	Lesões de leishmaniose'
JCSC_84455_LC (18).JPG'	Lesões de leishmaniose'
JSVL_2180_LC (1).JPG'	Lesões de leishmaniose'
JSVL_280_LC (3).JPG'	Lesões de leishmaniose'
JSVL_280_LC (5).JPG'	Lesões de leishmaniose'

JSVL_280_LC (8).JPG'	Lesões de leishmaniose'
JMN_88647_LC (17).JPG'	Lesões de leishmaniose'
JMN_88647_LC (5).JPG'	Lesões de leishmaniose'
JRS_86521_LC (10).JPG'	Lesões de leishmaniose'
JRS_86521_LC (11).JPG'	Lesões de leishmaniose'
JBLS_84077_LC (1).JPG'	Lesões de leishmaniose'
JBLS_84077_LC (7).JPG'	Lesões de leishmaniose'
JFFL_83861_LC (5).JPG'	Lesões de leishmaniose'
JFFL_83861_LC (7).JPG'	Lesões de leishmaniose'
JFFL_83861_LC (8).JPG'	Lesões de leishmaniose'
JLBD_84395_LC (10).JPG'	Lesões de leishmaniose'
JLBD_84395_LC (9).JPG'	Lesões de leishmaniose'
JPCF_86700_LC (8).JPG'	Lesões de leishmaniose'
JFS_86426_LC (13).JPG'	Lesões de leishmaniose'
JFS_86426_LC (7).JPG'	Lesões de leishmaniose'
JFS_86426_LC (8).JPG'	Lesões de leishmaniose'
JFS_86426_LC (9).JPG'	Lesões de leishmaniose'
JCM_84530_LC (1).JPG'	Lesões de leishmaniose'
JCM_84530_LC (9).JPG'	Lesões de leishmaniose'
JONF_86371_LC (5).JPG'	Lesões de leishmaniose'
JONF_86371_LC (6).JPG'	Lesões de leishmaniose'
JRC_81129_LC (2).JPG'	Lesões de leishmaniose'
JRC_81129_LC (3).JPG'	Lesões de leishmaniose'
JRC_81129_LC (4).JPG'	Lesões de leishmaniose'
JRC_81129_LC (5).JPG'	Lesões de leishmaniose'
JJS_72328_LC (4).JPG'	Lesões de leishmaniose'
JJS_72328_LC(6).JPG'	Lesões de leishmaniose'
JMB_84766_LC (1).JPG'	Lesões de leishmaniose'
JMB_84766_LC (6).JPG'	Lesões de leishmaniose'
JMB_84766_LC (7).JPG'	Lesões de leishmaniose'
JRC_90334_LC (8).JPG'	Lesões de leishmaniose'
JHF_05676_LC (5).JPG'	Lesões de leishmaniose'
JHF_05676_LC (6).JPG'	Lesões de leishmaniose'
JRBS_78549_LC (5).JPG'	Lesões de leishmaniose'
KSD_82546_LC (3).JPG'	Lesões de leishmaniose'
KSD_82546_LC (4).JPG'	Lesões de leishmaniose'
KGMS_85297_LC (11).JPG'	Lesões de leishmaniose'
KGMS_85297_LC (2).JPG'	Lesões de leishmaniose'
LJBC_84025_LC (4).JPG'	Lesões de leishmaniose'
LCC_86958 (6).JPG'	Lesões de leishmaniose'
LPM_82575_LC (2).JPG'	Lesões de leishmaniose'
LFTLG_85336_LC (3).JPG'	Lesões de leishmaniose'
LFTLG_85336_LC (4).JPG'	Lesões de leishmaniose'
LFTLG_85336_LC (5).JPG'	Lesões de leishmaniose'

MAC_85420_LC (11).JPG'	Lesões de leishmaniose'
MAPB_86299_LC (6).JPG'	Lesões de leishmaniose'
MAPB_86299_LC (8).JPG'	Lesões de leishmaniose'
MWMN_84238_LC (6).JPG'	Lesões de leishmaniose'
MWMN_84238_LC (9).JPG'	Lesões de leishmaniose'
MAC_84826_LC (1).JPG'	Lesões de leishmaniose'
MAC_84826_LC (15).JPG'	Lesões de leishmaniose'
MAC_84826_LC (9).JPG'	Lesões de leishmaniose'
MBBR_85993_LC (6).JPG'	Lesões de leishmaniose'
MCAR_85976_LC (10).JPG'	Lesões de leishmaniose'
MCAR_85976_LC (11).JPG'	Lesões de leishmaniose'
MCAR_85976_LC (12).JPG'	Lesões de leishmaniose'
MCPS_81271_LC (1).JPG'	Lesões de leishmaniose'
MCPS_81271_LC(4).JPG'	Lesões de leishmaniose'
MSSN_84947_LC (4).JPG'	Lesões de leishmaniose'
MSSN_84947_LC (5).JPG'	Lesões de leishmaniose'
MSSN_84947_LC (8).JPG'	Lesões de leishmaniose'
MHCS_85704_LC (1).JPG'	Lesões de leishmaniose'
MHCS_85704_LC (4).JPG'	Lesões de leishmaniose'
MHCS_85704_LC (5).JPG'	Lesões de leishmaniose'
MHCS_85704_LC (8).JPG'	Outros tipos de lesões'
MHCS_85704_LC (9).JPG'	Lesões de leishmaniose'
MMF_85778_LC (14).JPG'	Lesões de leishmaniose'
MMF_85778_LC (17).JPG'	Lesões de leishmaniose'
MMF_85778_LC (18).JPG'	Lesões de leishmaniose'
MMF_85778_LC (22).JPG'	Lesões de leishmaniose'
MMLS_84879_LC (1).JPG'	Lesões de leishmaniose'
MMLS_84879_LC (7).JPG'	Lesões de leishmaniose'
MRSS_85199_LC (6).JPG'	Lesões de leishmaniose'
MTJA_56036_LC (1).JPG'	Lesões de leishmaniose'
MTJA_56036_LC (10).JPG'	Lesões de leishmaniose'
MTJA_56036_LC (11).JPG'	Lesões de leishmaniose'
MTJA_56036_LC (12).JPG'	Lesões de leishmaniose'
MTJA_56036_LC (14).JPG'	Lesões de leishmaniose'
MTJA_56036_LC (19).JPG'	Lesões de leishmaniose'
MATB_26499_LC(4).JPG'	Lesões de leishmaniose'
MATB_26499_LC(5).JPG'	Lesões de leishmaniose'
MABC_84017_LC (1).JPG'	Lesões de leishmaniose'
MABC_84017_LC (2).JPG'	Lesões de leishmaniose'
MBJ_70782_LC (4).JPG'	Lesões de leishmaniose'
MOA_85592_LC_13 (28).JPG'	Lesões de leishmaniose'
MOA_85592_LC_13 (32).JPG'	Lesões de leishmaniose'
MOA_85592_LC_13 (33).JPG'	Lesões de leishmaniose'
MOA_85592_LC_13 (35).JPG'	Lesões de leishmaniose'

MOA_85592_LC_13 (44).JPG'	Lesões de leishmaniose'
MOA_88322_LC (2).JPG'	Lesões de leishmaniose'
MOA_88322_LC (7).JPG'	Lesões de leishmaniose'
MPS_88873_LC (12).JPG'	Lesões de leishmaniose'
MPS_88873_LC (16).JPG'	Lesões de leishmaniose'
MPS_88873_LC (4).JPG'	Lesões de leishmaniose'
MSB_88173_LC (10).JPG'	Lesões de leishmaniose'
MSB_88173_LC (11).JPG'	Lesões de leishmaniose'
MSB_88173_LC (16).JPG'	Lesões de leishmaniose'
MSB_88173_LC (5).JPG'	Lesões de leishmaniose'
MSB_88173_LC (7).JPG'	Lesões de leishmaniose'
MSB_88173_LC (8).JPG'	Lesões de leishmaniose'
MLC_79316_LC (4).JPG'	Lesões de leishmaniose'
MSB_78556_LC (4).JPG'	Lesões de leishmaniose'
MLM_86568_LC (1).JPG'	Lesões de leishmaniose'
MLM_86568_LC (10).JPG'	Lesões de leishmaniose'
MLM_86568_LC (12).JPG'	Lesões de leishmaniose'
MLM_86568_LC (13).JPG'	Lesões de leishmaniose'
MLM_86568_LC (8).JPG'	Lesões de leishmaniose'
NBS_84628_LC (3).JPG'	Lesões de leishmaniose'
NBS_84628_LC (7).JPG'	Lesões de leishmaniose'
NCA_20888_LC (2).JPG'	Lesões de leishmaniose'
NCA_20888_LC (5).JPG'	Lesões de leishmaniose'
NSA_84016_LC (12).JPG'	Lesões de leishmaniose'
NSA_84016_LC (15).JPG'	Lesões de leishmaniose'
NSA_84016_LC (18).JPG'	Lesões de leishmaniose'
NSA_84016_LC (2).JPG'	Lesões de leishmaniose'
NSA_84016_LC (21).JPG'	Lesões de leishmaniose'
NSA_84016_LC (23).JPG'	Lesões de leishmaniose'
NSA_84016_LC (4).JPG'	Lesões de leishmaniose'
NSA_84016_LC (6).JPG'	Lesões de leishmaniose'
NSA_84016_LC (7).JPG'	Lesões de leishmaniose'
NSA_84016_LC (8).JPG'	Lesões de leishmaniose'
NRR_86696_LC (6).JPG'	Lesões de leishmaniose'
NRR_86696_LC (7).JPG'	Lesões de leishmaniose'
OSL_27557_LC(13).JPG'	Lesões de leishmaniose'
OSL_27557_LC (7).JPG'	Lesões de leishmaniose'
OSL_27557_LC (1).JPG'	Lesões de leishmaniose'
PKMLC_84031_LC (10).JPG'	Lesões de leishmaniose'
PKMLC_84031_LC (12).JPG'	Lesões de leishmaniose'
PKMLC_84031_LC (17).JPG'	Lesões de leishmaniose'
PKMLC_84031_LC (8).JPG'	Lesões de leishmaniose'
PHVCSC_84044_LC(15).JPG'	Lesões de leishmaniose'
PHVCSC_84044_LC(21).JPG'	Lesões de leishmaniose'

PHVCSC_84044_LC(25).JPG'	Lesões de leishmaniose'
PHVCSC_84044_LC(26).JPG'	Lesões de leishmaniose'
PJMM_90869_LC (2).JPG'	Lesões de leishmaniose'
RBS_86925_LC (10).JPG'	Lesões de leishmaniose'
RSS_84951_LC (1).JPG'	Lesões de leishmaniose'
RSS_84951_LC (5).JPG'	Lesões de leishmaniose'
RCM_86771_LC (19).JPG'	Lesões de leishmaniose'
RCM_86771_LC (20).JPG'	Lesões de leishmaniose'
RCM_86771_LC (9).JPG'	Lesões de leishmaniose'
RPA_87608_LC (1).JPG'	Lesões de leishmaniose'
RPA_87608_LC (14).JPG'	Lesões de leishmaniose'
RPA_87608_LC (15).JPG'	Lesões de leishmaniose'
RPA_87608_LC (4).JPG'	Lesões de leishmaniose'
RLS_80973_LC (18).JPG'	Lesões de leishmaniose'
RLS_80973_LC (20).JPG'	Lesões de leishmaniose'
RLS_80973_LC (23).JPG'	Lesões de leishmaniose'
RLS_80973_LC (28).JPG'	Lesões de leishmaniose'
RLS_80973_LC (29).JPG'	Lesões de leishmaniose'
RLS_80973_LC (30).JPG'	Lesões de leishmaniose'
RLS_80973_LC (31).JPG'	Lesões de leishmaniose'
RLS_80973_LC (38).JPG'	Lesões de leishmaniose'
SBD_85168_LC (10).JPG'	Lesões de leishmaniose'
SRSF_86531_LC (4).JPG'	Lesões de leishmaniose'
STSP_22520_LC (1).JPG'	Lesões de leishmaniose'
STSP_22520_LC (5).JPG'	Lesões de leishmaniose'
TAB_86523_LC (5).JPG'	Lesões de leishmaniose'
TPV_84919_LC (10).JPG'	Lesões de leishmaniose'
TPV_84919_LC (12).JPG'	Lesões de leishmaniose'
TPV_84919_LC (9).JPG'	Lesões de leishmaniose'
VJN_85150_LC (14).JPG'	Lesões de leishmaniose'
VJN_85150_LC (21).JPG'	Lesões de leishmaniose'
VJN_85150_LC (24).JPG'	Lesões de leishmaniose'
VJN_85150_LC (25).JPG'	Lesões de leishmaniose'
VAN_90245_LC (5).JPG'	Lesões de leishmaniose'
VAN_90245_LC (7).JPG'	Lesões de leishmaniose'
VSO_18786_LC (1).JPG'	Lesões de leishmaniose'
VSO_18786_LC (2).JPG'	Lesões de leishmaniose'
VSO_18786_LC (5).JPG'	Lesões de leishmaniose'
VSO_18786_LC (15).JPG'	Lesões de leishmaniose'
VSO_18786_LC (17).JPG'	Lesões de leishmaniose'
VSO_18786_LC (8).JPG'	Lesões de leishmaniose'
VDS_88810_LC (4).JPG'	Lesões de leishmaniose'
VJN_85150_LC (1).JPG'	Lesões de leishmaniose'
WASL_88534_LC (3).JPG'	Lesões de leishmaniose'

WASL_88534_LC (5).JPG'	Lesões de leishmaniose'
WBS_76712_LC (16).JPG'	Lesões de leishmaniose'
WBS_76712_LC (18).JPG'	Lesões de leishmaniose'
WBS_76712_LC (8).JPG'	Lesões de leishmaniose'
WLP_88225_LC (2).JPG'	Lesões de leishmaniose'
WLP_88225_LC (7).JPG'	Lesões de leishmaniose'
WLP_88225_LC (8).JPG'	Lesões de leishmaniose'
ASM_39829_CEC (12).JPG'	Outros tipos de lesões'
ADE_86056_ECZ (13).JPG'	Outros tipos de lesões'
ADE_86056_ECZ (17).JPG'	Lesões de leishmaniose'
ADE_86056_ECZ (18).JPG'	Lesões de leishmaniose'
ADE_86056_ECZ (2).JPG'	Outros tipos de lesões'
ADE_86056_ECZ (7).JPG'	Lesões de leishmaniose'
AKRW_81602_TIC (1).JPG'	Lesões de leishmaniose'
AKRW_81602_TIC (3).JPG'	Outros tipos de lesões'
AKRW_81602_TIC (37).JPG'	Outros tipos de lesões'
ABS_85306_IVC (7).JPG'	Outros tipos de lesões'
AJB_86684_IVC(6).JPG'	Outros tipos de lesões'
AJB_86684_IVC (9).JPG'	Outros tipos de lesões'
CNM_85338_HAN(13).JPG'	Outros tipos de lesões'
CNM_85338_HAN(18).JPG'	Outros tipos de lesões'
CNM_85338_HAN(20).JPG'	Outros tipos de lesões'
CNM_85338_HAN(21).JPG'	Outros tipos de lesões'
CNM_85338_HAN(22).JPG'	Outros tipos de lesões'
CNM_85338_HAN(3).JPG'	Outros tipos de lesões'
CLS_35167_VSL (10).JPG'	Outros tipos de lesões'
CLS_35167_VSL (7).JPG'	Outros tipos de lesões'
DSC_47487_LFC (1).JPG'	Outros tipos de lesões'
DSC_47487_LFC (5).JPG'	Outros tipos de lesões'
EAM_89659_HAN (14).JPG'	Outros tipos de lesões'
EAM_89659_HAN (15).JPG'	Outros tipos de lesões'
EAM_89659_HAN (18).JPG'	Outros tipos de lesões'
EAM_89659_HAN (31).JPG'	Lesões de leishmaniose'
EAM_89659_HAN (32).JPG'	Outros tipos de lesões'
EAM_89659_HAN (35).JPG'	Outros tipos de lesões'
EAM_89659_HAN (5).JPG'	Outros tipos de lesões'
EAM_89659_HAN (6).JPG'	Outros tipos de lesões'
EAM_89659_HAN (8).JPG'	Outros tipos de lesões'
ECC_88279_EPT (8).JPG'	Outros tipos de lesões'
ECC_88279_EPT (9).JPG'	Outros tipos de lesões'
EMN_11153_ECT (11).JPG'	Lesões de leishmaniose'
EMN_11153_ECT (2).JPG'	Outros tipos de lesões'
EDL_85289_EPF (4).JPG'	Lesões de leishmaniose'
EBN_85447_CBC (5).JPG'	Outros tipos de lesões'

EBN_85447_CBC (8).JPG'	Outros tipos de lesões'
GAN_49596_IVC (2).JPG'	Outros tipos de lesões'
GAN_49596_IVC (3).JPG'	Outros tipos de lesões'
GAN_49596_IVC (4).JPG'	Outros tipos de lesões'
GSN_88162_IMP (13).JPG'	Outros tipos de lesões'
GSN_88162_IMP (21).JPG'	Outros tipos de lesões'
GSN_88162_IMP (23).JPG'	Outros tipos de lesões'
GSN_88162_IMP (26).JPG'	Lesões de leishmaniose'
GSN_88162_IMP (8).JPG'	Outros tipos de lesões'
HAB_57265_CEC (1).JPG'	Outros tipos de lesões'
HAB_5795265_CEC (3).JPG'	Outros tipos de lesões'
HAB_5795265_CEC (8).JPG'	Outros tipos de lesões'
IMM_8614646_SIT (10).JPG'	Outros tipos de lesões'
IMM_8614646_SIT (5).JPG'	Outros tipos de lesões'
IMM_8614646_SIT (6).JPG'	Lesões de leishmaniose'
IMM_86646_SIT (7).JPG'	Outros tipos de lesões'
INS_90288_CBM (16).JPG'	Outros tipos de lesões'
INS_90288_CBM (24).JPG'	Outros tipos de lesões'
INS_90288_CBM (28).JPG'	Outros tipos de lesões'
INS_90288_CBM (3).JPG'	Outros tipos de lesões'
INS_90288_CBM (37).JPG'	Outros tipos de lesões'
INS_90288_CBM (6).JPG'	Outros tipos de lesões'
INS_90288_CBM (9).JPG'	Outros tipos de lesões'
IMC_83543_IVC (8).JPG'	Outros tipos de lesões'
JAF_86633_ECT (17).JPG'	Outros tipos de lesões'
JAF_86633_ECT (18).JPG'	Outros tipos de lesões'
JAF_86633_ECT (20).JPG'	Outros tipos de lesões'
JAF_86633_ECT (25).JPG'	Lesões de leishmaniose'
JAF_86633_ECT (27).JPG'	Lesões de leishmaniose'
JBS_81336_PSO (2).JPG'	Outros tipos de lesões'
JFA_88020_LSC (14).JPG'	Outros tipos de lesões'
JRR_55758_PCT (2).JPG'	Outros tipos de lesões'
JRR_55758_PCT (5).JPG'	Outros tipos de lesões'
JRR_55758_PCT (6).JPG'	Outros tipos de lesões'
JRR_55758_PCT (7).JPG'	Outros tipos de lesões'
LCSP_88140_ECT (27).JPG'	Outros tipos de lesões'
LCSP_88140_ECT (31).JPG'	Outros tipos de lesões'
LAC_84233_PDT (11).JPG'	Outros tipos de lesões'
LAC_84233_PDT (5).JPG'	Outros tipos de lesões'
LIA_64743_PDT (1).JPG'	Outros tipos de lesões'
MMA_88125_IVC (9).JPG'	Lesões de leishmaniose'
MMA_88125_IVC (3).JPG'	Lesões de leishmaniose'
MMA_88125_IVC (7).JPG'	Lesões de leishmaniose'
MRAJ_88204 (5).JPG'	Outros tipos de lesões'

MFMS_26609_ECT (1).JPG'	Outros tipos de lesões'
MFMS_26609_ECT (11).JPG'	Outros tipos de lesões'
MFMS_26609_ECT (13).JPG'	Outros tipos de lesões'
MFMS_26609_ECT (9).JPG'	Outros tipos de lesões'
MFRS_88083_ECZ (27).JPG'	Lesões de leishmaniose'
MLSQ_57377_ESP (14).JPG'	Outros tipos de lesões'
MLSQ_57377_ESP(16).JPG'	Outros tipos de lesões'
MLSQ_57377_ESP (24).JPG'	Outros tipos de lesões'
MLSQ_57377_ESP (3).JPG'	Lesões de leishmaniose'
MLSQ_57377_ESP (4).JPG'	Lesões de leishmaniose'
MLSQ_57377_ESP (8).JPG'	Lesões de leishmaniose'
MMCA_36348_PDT (18).JPG'	Outros tipos de lesões'
MCA_36348_PDT (24).JPG'	Outros tipos de lesões'
MCA_36348_PDT (27).JPG'	Outros tipos de lesões'
MCA_36348_PDT (28).JPG'	Outros tipos de lesões'
MCA_36348_PDT (6).JPG'	Outros tipos de lesões'
NFR_79950_PDT (5).JPG'	Outros tipos de lesões'
NFR_79950_PDT (6).JPG'	Outros tipos de lesões'
OSG_86518_IVC (10).JPG'	Outros tipos de lesões'
OSG_86518_IVC (13).JPG'	Outros tipos de lesões'
OSG_86518_IVC (2).JPG'	Outros tipos de lesões'
OSG_86518_IVC (20).JPG'	Outros tipos de lesões'
OSG_86518_IVC (21).JPG'	Outros tipos de lesões'
OSG_86518_IVC (6).JPG'	Outros tipos de lesões'
OSSG_83978_CBM (11).JPG'	Outros tipos de lesões'
OSSG_83978_CBM (17).JPG'	Outros tipos de lesões'
OSSG_83978_CBM (7).JPG'	Outros tipos de lesões'
PRV_85063_CBC (2).JPG'	Outros tipos de lesões'
PRV_85063_CBC (9).JPG'	Lesões de leishmaniose'
PMV_76819_CAT (7).JPG'	Outros tipos de lesões'
RCMS_85120_PDT (1).JPG'	Outros tipos de lesões'
RCMS_85120_PDT (12).JPG'	Outros tipos de lesões'
RCMS_85120_PDT (15).JPG'	Outros tipos de lesões'
RCMS_85120_PDT (24).JPG'	Outros tipos de lesões'
RRCMS_85120_PDT (25).JPG'	Lesões de leishmaniose'
RCMS_85120_PDT (29).JPG'	Outros tipos de lesões'
RCMS_85120_PDT (5).JPG'	Outros tipos de lesões'
RFS_86719_LED (16).JPG'	Lesões de leishmaniose'
RFS_86719_LED (4).JPG'	Outros tipos de lesões'
RFS_86719_LED (6).JPG'	Outros tipos de lesões'
RFS_86719_LED (6).JPG'	Outros tipos de lesões'
RNMS_84727_LIP (6).JPG'	Outros tipos de lesões'
RNMS_84727_LIP (7).JPG'	Outros tipos de lesões'
RBV_90076_LIP (10).JPG'	Lesões de leishmaniose'

RBV_90076_LIP (9).JPG'	Outros tipos de lesões'
RBR_88761_PDT (36).JPG'	Outros tipos de lesões'
RBR_88761_PDT (39).JPG'	Outros tipos de lesões'
RBR_88761_PDT (41).JPG'	Outros tipos de lesões'
RRLS_30850_LNF (1).JPG'	Outros tipos de lesões'
SRB_11296_EPT (4).JPG'	Outros tipos de lesões'
VAL_88190_PCM (7).JPG'	Outros tipos de lesões'
VGL_85745_IVC (1).JPG'	Outros tipos de lesões'
VGL_85745_IVC (7).JPG'	Outros tipos de lesões'

ANEXO A - Aprovação do Comitê de Ética em Pesquisa

FACULDADE DE MEDICINA DA
UNIVERSIDADE DE BRASÍLIA -
UNB



PARECER CONSUBSTANCIADO DO CEP

DADOS DO PROJETO DE PESQUISA

Título da Pesquisa: Identificação automática de imagens de lesões cutâneas resultantes de doenças tropicais negligenciadas

Pesquisador: Rodrigo Gurgel Gonçalves

Área Temática:

Versão: 2

CAAE: 68696323.5.0000.5558

Instituição Proponente: Faculdade de Medicina da Universidade de Brasília - UNB

Patrocinador Principal: Financiamento Próprio

DADOS DO PARECER

Número do Parecer: 6.274.867

Apresentação do Projeto:

Trata-se de projeto de mestrado em Medicina Tropical da UnB, em colaboração entre equipe de pesquisa em Parasitologia da FM-UnB e profissionais do ambulatório de dermatologia do HUB. O projeto tem como foco as doenças tropicais negligenciadas, importantes problemas de saúde pública. Várias dessas doenças têm manifestações cutâneas, cujo diagnóstico depende de avaliação por especialistas.

Neste projeto, os pesquisadores propõe usar estratégias de aprendizado de máquina para identificação automatizada de etiologia de lesões de pele com base em imagens de lesões de pacientes atendidos no ambulatório do HUB no período de 2015 a 2022. Essas imagens serão analisadas com ferramentas de inteligência artificial, e os resultados comparados com o diagnóstico feito por especialistas.

Objetivo da Pesquisa:

No projeto, os pesquisadores afirmam que o objetivo da pesquisa é "Avaliar o desempenho dos algoritmos de aprendizado de máquina para identificar imagens de lesões de pele focando nas doenças infecciosas e parasitárias negligenciadas." Os objetivos específicos são:

"Confirmar o diagnóstico das imagens a partir de resultados dos exames clínicos e laboratoriais

Endereço: Universidade de Brasília, Campus Universitário Darcy Ribeiro - Faculdade de Medicina

Bairro: Asa Norte

CEP: 70.910-900

UF: DF

Município: BRASILIA

Telefone: (61)31071-7170

E-mail: cepfm@unb.br



Continuação do Parecer: 6.274.867

para definição do grupo de imagens "gold standard". Verificar o desempenho de diferentes algoritmos (AlexNet, Linear Discriminant Analysis e Histogram-based Gradient Boosting) baseados em aprendizado de máquina para diferenciar lesões de pele causadas por doenças tropicais negligenciadas. Avaliar o desempenho dos algoritmos em diferentes características do paciente: cor da pele, sexo e idade."

Avaliação dos Riscos e Benefícios:

No projeto básico, os pesquisadores afirmam o seguinte: "Há risco para a privacidade dos participantes, pois a pesquisa utilizará imagens das lesões dos pacientes atendidos no ambulatório de Dermatologia do HUB." Adicionalmente, no projeto citam que "Sabemos do Risco de constrangimento, assim as imagens não são identificadas com nome e são salvas em disco criptografado para proteger a identidade dos participantes."

Sobre os benefícios, o projeto traz o seguinte: "o paciente participante da pesquisa não é beneficiado diretamente, ainda que a identificação automática de lesões cutâneas de doenças tropicais negligenciadas por algoritmos de aprendizado de máquina possa se tornar uma importante ferramenta de suporte profissional durante o diagnóstico."

Comentários e Considerações sobre a Pesquisa:

Trata-se de pesquisa importante em termos de saúde pública, por prever a criação de ferramentas que possam ajudar a melhor diagnosticar doenças tropicais negligenciadas. A equipe de pesquisa multidisciplinar inclui alunos e pesquisadores, assim como profissionais de saúde especialistas em manifestações cutâneas de doenças tropicais negligenciadas.

Esta é a segunda versão do projeto, com modificações em resposta às pendências elencadas no parecer anterior.

Considerações sobre os Termos de apresentação obrigatória:

No parecer anterior, este CEP elencou pendências no projeto. Os pesquisadores anexaram novos documentos ao processo, com modificações. Anexaram também carta com resposta às pendências, que seguem abaixo:

1) Em toda pesquisa com seres humanos há risco. Neste projeto, há risco para a privacidade dos participantes. Os documentos do projeto devem ser mudados para incluir essa informação. Os pesquisadores corrigiram a análise de riscos nos documentos do projeto.

Endereço: Universidade de Brasília, Campus Universitário Darcy Ribeiro - Faculdade de Medicina
Bairro: Asa Norte **CEP:** 70.910-900
UF: DF **Município:** BRASÍLIA
Telefone: (61)31071-7170 **E-mail:** cepfm@unb.br

FACULDADE DE MEDICINA DA
UNIVERSIDADE DE BRASÍLIA -
UNB



Continuação do Parecer: 6.274.867

2) A análise de benefícios de um estudo com seres humanos deve ser focada nos benefícios para o participante, não para a instituição ou para o sistema de saúde. No caso deste projeto, não há benefício direto para o participante, sendo sua participação altruísta. Isso deve ser esclarecido nos documentos do projeto.

A análise de benefícios também foi corrigida.

3) Os pesquisadores pedem autorização para dispensa de TCLE. A resolução 466/2012 estabelece que "Nos casos em que seja inviável a obtenção do Termo de Consentimento Livre e Esclarecido ou que esta obtenção signifique riscos substanciais à privacidade e confidencialidade dos dados do participante ou aos vínculos de confiança entre pesquisador e pesquisado, a dispensa do TCLE deve ser justificadamente solicitada pelo pesquisador responsável ao Sistema CEP/CONEP, para apreciação, sem prejuízo do posterior processo de esclarecimento." Como o projeto irá coletar imagens prospectivamente, e a equipe inclui profissionais de saúde do ambulatório de dermatologia, não é inviável coletar o TCLE. Além disso, o consentimento neste projeto é importante porque serão coletadas fotografias do corpo dos pacientes.

4) Além do TCLE, é preciso acrescentar um "Termo de Cessão de Uso de Imagem e/ou Voz".

Resposta aos itens 3 e 4:

Após analisar o parecer, a equipe decidiu incluir somente as fotos (pré-existent) já obtidas de forma retrospectiva de 2015 a 2022, pois já são retiradas por necessidade do ambulatório de Dermatologia e não interfere na assistência ao paciente. Logo, entendemos que não há necessidade de TCLE e termo de Cessão de Uso de Imagem e/ou Voz.

Enviamos o projeto com as correções no texto e no cronograma.

5) É importante justificar o tamanho amostral de 600 participantes, por exemplo com análise de poder estatístico.

Os pesquisadores apresentam justificativa adequada para o tamanho amostral.

6) Esclarecer se serão feitas fotografias de lesões localizada na ou próximo à face dos participantes.

O banco de imagens disponibilizadas inclui algumas de lesões na face, porém serão recortadas no tamanho 227 x 227 para que não seja identificado o paciente e para melhorar a qualidade visual,

Endereço: Universidade de Brasília, Campus Universitário Darcy Ribeiro - Faculdade de Medicina

Bairro: Asa Norte

CEP: 70.910-900

UF: DF

Município: BRASÍLIA

Telefone: (61)31071-7170

E-mail: cepfm@unb.br

FACULDADE DE MEDICINA DA
UNIVERSIDADE DE BRASÍLIA -
UNB



Continuação do Parecer: 6.274.867

objetivando remover áreas indesejadas e destacando a região de interesse (lesão). Sabemos do Risco de constrangimento, assim as imagens não são identificadas com nome e são salvas em disco criptografado para proteger a identidade dos participantes.

Conclusões ou Pendências e Lista de Inadequações:

Tendo sido atendidas as pendências, meu parecer é pela aprovação deste projeto.

Considerações Finais a critério do CEP:

Após apreciação na reunião dia 30/08/2023 do colegiado CEP/FM o projeto foi aprovado. OBS: De acordo com a Resolução CNS 466/12, nos inciso II.19 e II.20, cabe ao pesquisador elaborar e apresentar ao CEP os relatórios parciais e final do seu projeto de pesquisa. Bem como a notificação de eventos adversos, de emendas ou modificações no protocolo para apreciação do CEP

Este parecer foi elaborado baseado nos documentos abaixo relacionados:

Tipo Documento	Arquivo	Postagem	Autor	Situação
Informações Básicas do Projeto	PB_INFORMAÇÕES_BÁSICAS_DO_PROJETO_2094923.pdf	28/06/2023 12:41:53		Aceito
Outros	04_Carta_de_Encaminhamento_de_projetos.pdf	28/06/2023 12:39:53	Rodrigo Gurgel Gonçalves	Aceito
Outros	RESUMO_estruturado.pdf	28/06/2023 12:36:54	Rodrigo Gurgel Gonçalves	Aceito
Solicitação Assinada pelo Pesquisador Responsável	07_Solicitacao_de_Dispenza_do_TCLE.pdf	28/06/2023 12:35:45	Rodrigo Gurgel Gonçalves	Aceito
Outros	CARTA_RESPOSTA_AO_PARECER_DO_CEP.pdf	28/06/2023 12:33:11	Rodrigo Gurgel Gonçalves	Aceito
Projeto Detalhado / Brochura Investigador	Projeto_MestradoPPGMT.pdf	28/06/2023 12:31:36	Rodrigo Gurgel Gonçalves	Aceito
Cronograma	Cronograma_de_atividades.pdf	28/06/2023 12:30:17	Rodrigo Gurgel Gonçalves	Aceito
Declaração de concordância	termo_de_concordancia.pdf	10/04/2023 13:00:52	Rodrigo Gurgel Gonçalves	Aceito
Orçamento	09_planilha_orcamentaria.pdf	10/04/2023 12:45:31	Rodrigo Gurgel Gonçalves	Aceito
Folha de Rosto	FolhaDeRosto_RodrigoGurgel_assina	10/04/2023	Rodrigo Gurgel	Aceito

Endereço: Universidade de Brasília, Campus Universitário Darcy Ribeiro - Faculdade de Medicina
Bairro: Asa Norte **CEP:** 70.910-900
UF: DF **Município:** BRASÍLIA
Telefone: (61)31071-7170 **E-mail:** cepfm@unb.br

FACULDADE DE MEDICINA DA
UNIVERSIDADE DE BRASÍLIA -
UNB



Continuação do Parecer: 6.274.867

Folha de Rosto	do.pdf	12:20:22	Gonçalves	Aceito
----------------	--------	----------	-----------	--------

Situação do Parecer:

Aprovado

Necessita Apreciação da CONEP:

Não


BRASILIA, 31 de Agosto de 2023

Assinado por:
Antônio Carlos Rodrigues da Cunha
(Coordenador(a))

Endereço: Universidade de Brasília, Campus Universitário Darcy Ribeiro - Faculdade de Medicina
Bairro: Asa Norte **CEP:** 70.910-900
UF: DF **Município:** BRASILIA
Telefone: (61)31071-7170 **E-mail:** cepfm@unb.br

ANEXO B - Artigo Publicado**Automated Identification of Cutaneous Leishmaniasis Lesions Using Deep-Learning-Based Artificial Intelligence**

Revista *Biomedicines* (fator de impacto: 4,7)





Article

Automated Identification of Cutaneous Leishmaniasis Lesions Using Deep-Learning-Based Artificial Intelligence

José Fabrício de Carvalho Leal ^{1,2} , Daniel Holanda Barroso ³, Natália Santos Trindade ², Vinícius Lima de Miranda ² and Rodrigo Gurgel-Gonçalves ^{1,2,*} 

¹ Graduate Program in Tropical Medicine, Center for Tropical Medicine, Faculty of Medicine, University of Brasília–UnB, Brasília 70904-970, Brazil; fabriciolealc29@gmail.com

² Laboratory of Medical Parasitology and Vector Biology, Faculty of Medicine, University of Brasília–UnB, Brasília 70904-970, Brazil; nataliatrindadeunb@gmail.com (N.S.T.); viniciuslimabio@gmail.com (V.L.d.M.)

³ Postgraduate Program in Medical Sciences, Faculty of Medicine, University of Brasília–UnB, Brasília 70904-970, Brazil; danielhbarroso@unb.br

* Correspondence: gurgelrg@hotmail.com

Abstract: The polymorphism of cutaneous leishmaniasis (CL) complicates diagnosis in health care services because lesions may be confused with other dermatoses such as sporotrichosis, paracoccid-iocomycosis, and venous insufficiency. Automated identification of skin diseases based on deep learning (DL) has been applied to assist diagnosis. In this study, we evaluated the performance of AlexNet, a DL algorithm, to identify pictures of CL lesions in patients from Midwest Brazil. We used a set of 2458 pictures (up to 10 of each lesion) obtained from patients treated between 2015 and 2022 in the Leishmaniasis Clinic at the University Hospital of Brasilia. We divided the picture database into training (80%), internal validation (10%), and testing sets (10%), and trained and tested AlexNet to identify pictures of CL lesions. We performed three simulations and trained AlexNet to differentiate CL from 26 other dermatoses (e.g., chromomycosis, ecthyma, venous insufficiency). We obtained an average accuracy of 95.04% (Confidence Interval 95%: 93.81–96.04), indicating an excellent performance of AlexNet in identifying pictures of CL lesions. We conclude that automated CL identification using AlexNet has the potential to assist clinicians in diagnosing skin lesions. These results contribute to the development of a mobile application to assist in the diagnosis of CL in health care services.

Keywords: dermatology; leishmaniasis; diagnosis; AlexNet; machine learning; pictures



Citation: Leal, J.F.d.C.; Barroso, D.H.; Trindade, N.S.; Miranda, V.L.d.; Gurgel-Gonçalves, R. Automated Identification of Cutaneous Leishmaniasis Lesions Using Deep-Learning-Based Artificial Intelligence. *Biomedicines* **2024**, *12*, 12. <https://doi.org/10.3390/biomedicines12010012>

Academic Editor: Paul Rösch

Received: 23 November 2023

Revised: 12 December 2023

Accepted: 17 December 2023

Published: 20 December 2023



Copyright: © 2023 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

Leishmaniasis is an infectious, neglected, and emerging tropical disease caused by *Leishmania* parasites transmitted through the bite of infected sandflies. The clinical presentation of leishmaniasis varies depending on the *Leishmania* species and the interaction with the host. Cutaneous leishmaniasis (CL) is an ancient disease, described in Egyptian papyri from 2000 BC. In the 19th century, it was believed that CL was caused by fungi. Moreover, there have been descriptions of skin ulcers in the Andes and Central America, which have also been mistakenly identified as leprosy. These historical reports demonstrate the difficulty in diagnosing CL [1,2].

CL is caused mainly by *L. mexicana*, *L. amazonensis*, *L. braziliensis*, *L. panamensis*, *L. tropica*, *L. major*, and *L. aethiops*. An estimated 350 million people live in regions with active *Leishmania* transmission across five continents in approximately 100 countries [1]. The annual incidence rate of leishmaniasis ranges from 0.7 to 1 million cases [3]. Most cases of CL (85%) occur in ten countries (Afghanistan, Algeria, Brazil, Ethiopia, Iran, Peru, Sudan, Costa Rica, Colombia, and Syria) [3–5].

The most prevalent clinical form of leishmaniasis is CL, causing single or multiple exudative painless lesions with raised borders [3]. The lesions develop over weeks to

months when the papule enlarges to a nodule that ulcerates slowly. Although less common, leishmaniasis can also manifest as verrucous, nodular, tuberculous lesions, among other forms. CL is usually manifested as a self-limited ulcer that can heal spontaneously over 3–18 months but cases progress to more severe manifestations depending on parasite species [3,6–9]. The polymorphism of CL complicates diagnosis in health care services because lesions may be confused with other dermatoses caused by fungi (sporotrichosis, paracoccidioidomycosis, chromomycosis), bacteria (leprosy, pyodermitis, ecthyma) and non-infectious diseases (venous insufficiency, skin cancer). Differential diagnosis is important since similar diseases are common in CL endemic regions. The diagnosis depends on a detailed clinical assessment considering signs and symptoms, epidemiological data, and laboratory tests, resulting in delayed treatment. There is no single reference test for CL and a combination of different methods is recommended [3,10–14]. For this reason, the development of new diagnostic methods for CL is of fundamental importance.

Recent advances in artificial intelligence (AI) have revolutionized medicine, with machine learning (ML) algorithms and their identification capacity having an important application to help diagnosis [15–18]. Furthermore, dermatology has benefited from novel diagnostic tools. Computational algorithms have been applied to help dermatologists diagnose skin diseases, such as melanomas, improving accuracy and early detection [19–26]. However, there are few studies applying ML to diagnose dermatoses caused by infectious agents such as *Leishmania*. Bamorovat et al. [18], presented a new diagnostic and prognostic method for classifying CL including responsive and non-responsive patients, showing the potential for automatic identification of leishmaniasis using ML algorithms. Furthermore, Noureldeen et al. [27], showed a new diagnostic method of CL detection and classification with an ML model. A new step in this area is to analyze pictures of CL compared to other skin diseases caused by fungal and bacterial infections, and non-infectious diseases, and applying pre-trained neural networks such as AlexNet to aid in the diagnosis of CL.

Deep learning (DL) techniques have potential to benefit the diagnosis in dermatology through the analysis of pictures of skin lesions, as they extract patterns from pictures and make predictions from large databases. Given this, the application of the technique can be an important step to support an accurate diagnosis, facilitating and assisting clinical decision making [28–30]. Therefore, the present study aimed to evaluate the performance of the DL algorithm (AlexNet) in identifying pictures of CL lesions from patients in Midwest Brazil.

2. Materials and Methods

2.1. Study Design and Picture Database

We obtained pictures of skin lesions from patients attending from 2015 to 2022 in the Leishmaniasis Clinic at the University Hospital of Brasilia, a referral service for leishmaniasis diagnosis and treatment in the Brazilian mid-western region. In the first consultation, we photographed the skin lesions (up to 10 pictures of each patient lesion) with a Sony alpha 7 R III-ICLE-R7M2 camera (Sony Corp, Tokyo, Japan) and Sony FE 24–105 mm or F4 G OSS or Sony FE 35 mm f/2.8 lenses (Sony Corp, Tokyo, Japan). Moreover, skin biopsies and mucocutaneous smears were performed to confirm the diagnosis [31–33].

We classified patients according to the composite reference standard following the operational classification of the Brazilian Ministry of Health [34]. The diagnosis for CL was confirmed after the observation of compatible clinical symptoms, with two other non-parasitological positive tests (indirect immunofluorescence, Montenegro intradermal reaction) or one parasitological positive test (qPCR, culture, histopathology, or smear with amastigotes) (Figure 1). After clinical evaluation by the dermatologist, the lesions were subjected to additional tests to confirm leishmaniasis and other differential diagnoses. The color (erythematous, hypo or hyperpigmented), body location (upper limbs, lower limbs, face, or trunk), diameter and type of lesions (macule, papule, plaque, nodule, ulcer, vesicle, or blister) were recorded. Therefore, the final diagnosis was only established after

laboratory results were available and allowed dermatologists to communicate the diagnosis and begin treatment.

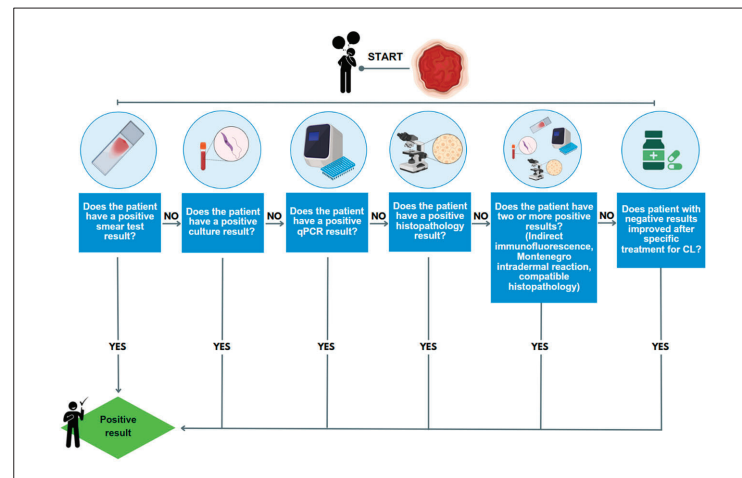


Figure 1. Patient flow at Leishmaniasis Clinic at the University Hospital of Brasilia. Source: created using [BioRender.com](#). Accessed on 19 October 2023.

We classified patients according to the composite reference standard [34]. Therefore, we included all patients with lesions that had diagnoses for CL and other dermatoses. We excluded patients if their skin lesions were located at mucous membranes, intimate body areas and the scalp, due to the difficulty of taking quality pictures without trichotomy. Patients who did not complete the diagnostic assessment were also excluded. The polymorphism of CL means that differential diagnosis with other diseases must always be considered. Therefore, patients diagnosed with other types of skin diseases also participated in this study (Table 1).

We obtained up to 10 pictures of each patient lesion: panoramic, close-up, lateral and edges. We identified pictures with an alphanumeric code and saved on these an encrypted disk to protect the participants' identity. Therefore, we created an image database with each type of skin lesion. We resized the pictures to improve visual quality, aiming to remove unwanted areas and highlight the region of interest. We cropped the pictures of facial lesions to avoid patient identification. Therefore, we compiled a database containing 1787 pictures of CL and 671 of other dermatoses (Table 1), resulting in a total of 2458 high-resolution pictures used to train and test the AlexNet algorithm (Figure 2).




Figure 2. Scheme summarizing research methods. (A) Pictures of skin lesions; (B) sorting into folders, resizing pictures and simulations; (C) analysis of AlexNet's performance. Source: created using [BioRender.com](#). Accessed on 19 October 2023.

Table 1. Number of pictures of skin lesions related to the classification group, according to etiology.

Group	Disease	<i>n</i>
Protozoosis	Cutaneous Leishmaniasis	1787
Bacterioses	Ecthyma	55
	Erysipelas	24
	Impetigo	26
	Leprosy	57
	Pyodermite	98
	Tertiary syphilis	12
	Subtotal	272
Fungal	Chromomycosis	56
	Lichen planus	18
	Lichen simplex chronicus	12
	Paracoccidioidomycosis	7
	Sporotrichosis	22
	Tinea corporis	18
	Subtotal	133
Non-infectious	Actinic keratosis	8
	Basal cell carcinoma (BCC)	31
	Dermatitis	12
	Discoid lupus erythematosus (DLE)	16
	Eczema	15
	Fixed pigmentary erythema	5
	Livedoid vasculitis	12
	Lymphocytoma cutis	8
	Lymphoma	9
	Porokeratosis	7
	Psoriasis	2
	Rosacea	3
	Squamous cell carcinoma (SCC)	40
	Venous insufficiency	98
	Subtotal	266
Grand total		2458

2.2. Algorithm: Training and Testing

We used a DL algorithm (AlexNet) to identify skin lesion pictures. AlexNet is a Convolutional Neural Network which has 60 million parameters and 650,000 neurons. AlexNet was pre-trained on 1.2 million images of varying resolution and representing 1000 classes (i.e., objects, animals, plants) from the ImageNet database [35]. AlexNet has been successfully used for automated identification of insect vectors [36,37] and disease diagnosis based on images [38,39].

AlexNet operates according to some fundamental components and principles: (1) it has five convolutional layers, responsible for extracting relevant features from the input images, which detect specific patterns, such as edges, textures and shapes; (2) it has max pooling layers that reduce the dimensionality of the image representation, preserving significant characteristics and reducing computational processing; (3) it uses the ReLU (Rectified Linear Unit) function in the convolutional layers to add non-linearity to the network, allowing it to learn more complexities in the data; (4) it uses the Local Response Normalization technique to normalize the outputs of the convolutional layers, promoting competition between neurons and increasing the generalization capacity; (5) in addition to the convolutional and pooling layers, it has three fully connected layers that combine the learned features to perform the final classification; (6) it employs the Dropout technique to combat overfitting, randomly deactivating some neurons during training, thus preventing

the network from becoming too dependent on some neurons; and (7) it uses the Softmax function to convert the network outputs into probabilities so that the highest probability is chosen as the final prediction [35].

We cropped all pictures into a square format (227×227 pixels) according to the input patterns required by the AlexNet. All pictures were saved in the red-green-blue (RGB) format at a 72 dpi resolution. We divided the picture database into training (80%), internal validation (10%) and testing sets (10%), and trained and tested AlexNet to identify skin lesion pictures. In the learning process, AlexNet randomly chose the training, internal validation, and test pictures. For training, we defined the maximum number of epochs for identifying CL lesions (Figure 3) versus other dermatoses (Figure 4) as 100. Furthermore, network analyzes were performed in the MATLAB computational environment (www.mathworks.com, accessed on 10 October 2023).




Figure 3. Examples of leishmaniasis skin lesions used in this study.




Figure 4. Examples of other types of skin lesions. (A) ecthyma; (B) erysipelas; (C) pyoderma; (D) tertiary syphilis; (E) sporotrichosis; (F) lichen planus; (G) lichen simplex chronicus; (H) tinea corporis; (I) SCC; (J) actinic keratosis; (K) porokeratosis; (L) venous insufficiency.

2.3. Data Analysis

We ran three simulations in AlexNet. First, we trained the algorithm to learn to distinguish CL lesions from other dermatoses. Next, we evaluated the performance of the algorithm using confusion matrices, analyzing the number of hits and identification errors, as well as the average network accuracy, sensitivity, and specificity. We used the following equations to calculate the ML performance indicators:

$$\text{Accuracy} = (\text{VP} + \text{VN}) / (\text{VP} + \text{FP} + \text{VN} + \text{FN})$$

$$\text{Sensitivity} = \text{VP} / (\text{VP} + \text{FN})$$

$$\text{Specificity} = \text{VN} / (\text{VN} + \text{FP})$$

VP = True positives;

VN = True negatives;

FP = False positives;

FN = False negatives.

We calculated frequencies and proportions with confidence intervals (Wilson binomial with a 95% score) using the 'Hmisc' package in the computational software R 4.2.1, together with the RStudio 2023.03.1.446 interface [40–43]. Therefore, the results were presented through descriptive tables and illustrative graphs.

2.4. Ethical Consideration

This study received approval from the Ethics and Research Committee of the Faculty of Medicine of the University of Brasília, CAAE: 68696323.5.0000.5558 and number: 035700/2023.

3. Results

3.1. Training

The results of the three simulations demonstrated significant progress, in which the validation accuracy achieved good results. The algorithm's training process was completed within 100 epochs and iterations. We observed that AlexNet learns from new data, because as the epochs progress, data accuracy increases and, consequently, the losses decrease (Supplementary Material Figure S1).

3.2. AlexNet Performance

Simulation 1 showed 465 correct identifications and 26 errors, with an accuracy of 94.70% (95% CI 92.35–96.36). Seven pictures of CL lesions were confused with lesions from other types of dermatoses, while nineteen lesions from other types of diseases were confused with CL (Figure 5A).

Simulation 2 showed 469 correct identifications and 22 errors, with an excellent accuracy of 95.51% (95% CI 93.30–97.02). Of the wrong pictures, three were of CL lesions that were confused with lesions from other types of dermatoses, and nineteen were of lesions from other types of dermatoses that were confused with CL (Figure 5B). In simulation 3, we obtained an accuracy of 94.90%, represented by 466 correct identifications and 25 errors (95% CI 92.59–96.52). In this simulation, three pictures of CL lesions were confused with other dermatoses. In contrast to the other two simulations, 22 pictures of other types of dermatoses were confused with CL (Figure 5C).

Among the 60 pictures of lesions from other dermatoses that were confused with CL in these three simulations, those with the highest percentage of errors were leprosy (16.7%), ecthyma (11.6%), BCC (10.0%), erysipelas (8.3%) and lichen planus (8.3%) (Figure 6).

During the three simulations, we achieved an average validation accuracy of 95.04% (95% CI 93.81–96.04), indicating excellent performance of the trained network for the task of identifying CL lesions. Figure 7 shows the accuracy, sensitivity, and specificity of each of the simulations with their respective confidence intervals.

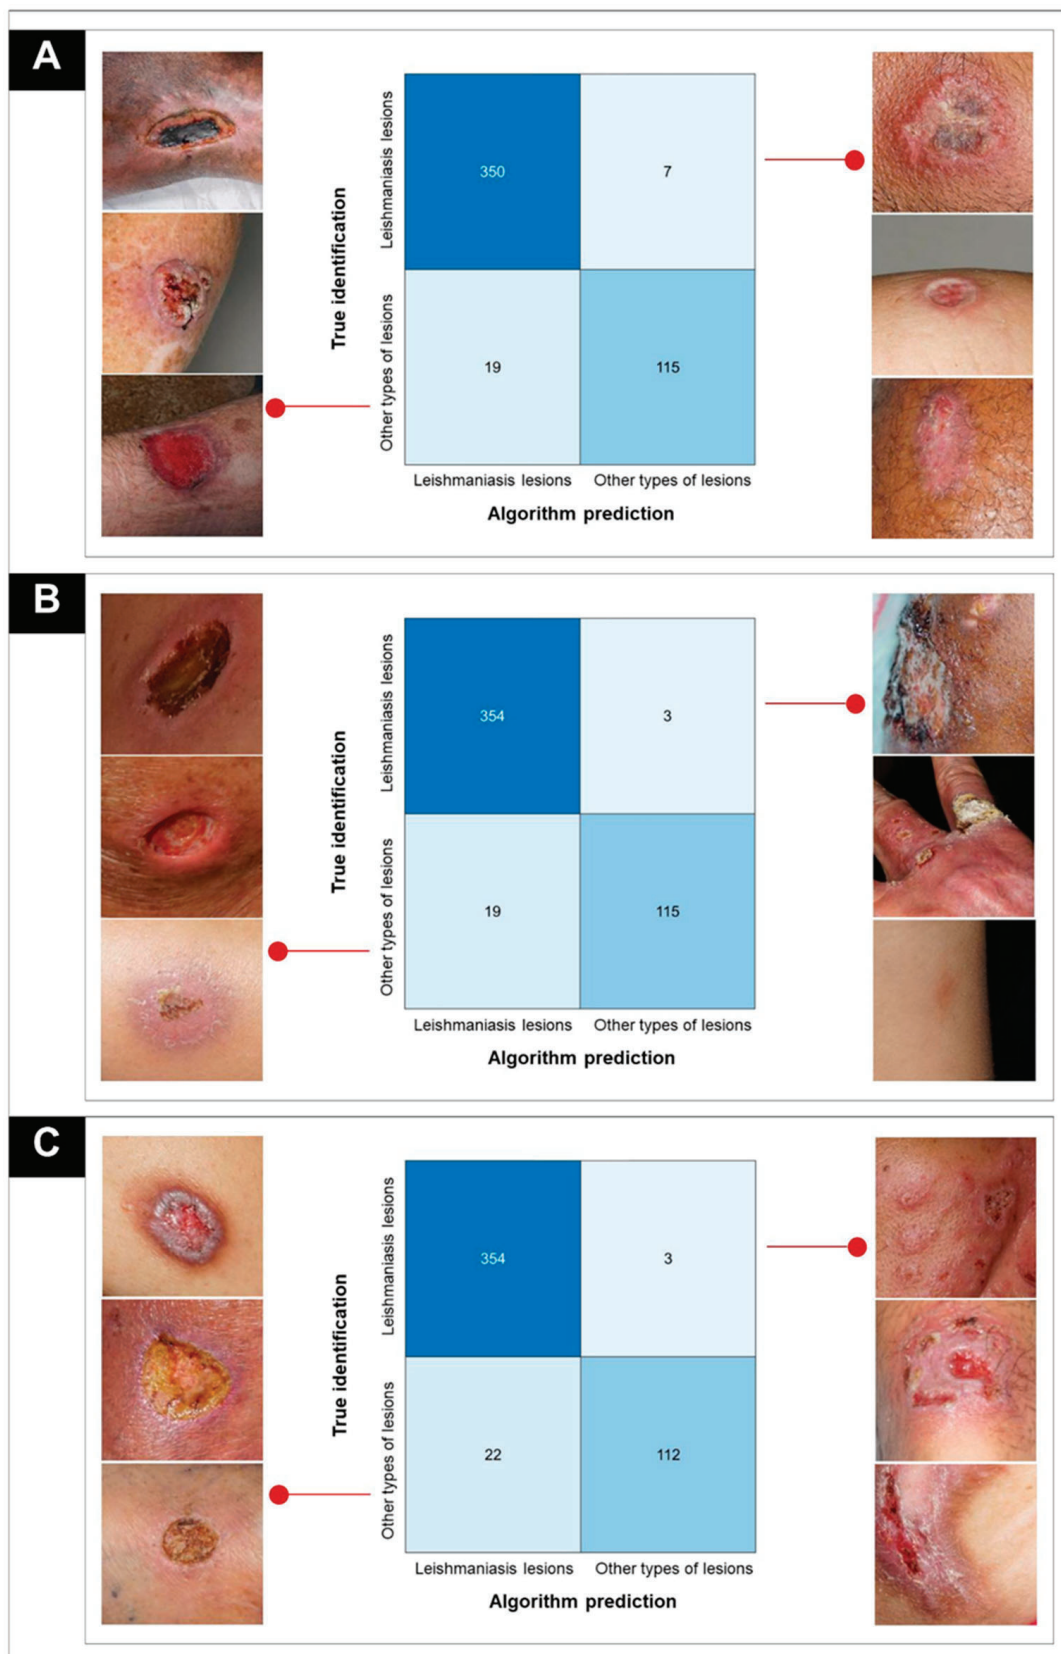


Figure 5. Confusion matrices of the simulations (cutaneous leishmaniasis lesions × lesions from other dermatoses) showing some of the CL pictures that were erroneously identified as other types of lesions using AlexNet and some pictures of other types of lesions that were erroneously identified as CL using AlexNet. (A) Simulation 1; (B) simulation 2; (C) simulation 3.




Figure 6. Percentage of dermatosis pictures incorrectly identified using the AlexNet network. Above each bar, there is the exact number of identifications as CL. BCC, DLE and SCC according to Table 1.




Figure 7. Accuracy, sensitivity, and specificity of the AlexNet network for identifying pictures of CL lesions with 95% Wilson confidence intervals (bars). Sim = simulation.

4. Discussion

Our results show an excellent performance of AlexNet in identifying pictures of CL lesions. These results pave the way to develop an AI system based on ML that can facilitate the diagnosis of CL lesions, assist clinicians in the differential diagnosis from other skin diseases, promote faster diagnostic, timely treatment, and consequently help improve the quality of life of patients diagnosed with CL.

Our database was built based on a cohort of patients treated at the Leishmaniasis Clinic of the University Hospital of Brasília over 8 years. All skin lesions were pictured during the patients' first contact. However, the pictures were only added to the database after a conclusive diagnosis of the skin disease [27–29] and they were separated into folders according to the disease. Therefore, the diagnosis followed the composite reference standard protocol established by the Brazilian Ministry of Health [34]. These data show that our database is reliable and based on a well-established diagnostic protocol to ensure the identification of the CL lesions included in this study, which were used for automated identification using AlexNet.

Technologies, medical interventions, and diagnostic tests are not perfect and must be evaluated before introduction into health care services. Therefore, diagnostic accuracy studies are important to discriminate between infected and non-infected individuals [44]. This ability can be quantified through measures such as sensitivity and specificity. Furthermore, the main objectives of diagnostic tests and other forms of testing should be to prevent early death, decrease suffering, and restore functional health. In this way, new tools that improve the diagnosis, support patients with the disease, and help clinicians to detect sick individuals should be developed [45,46].

AI refers to the ability of a machine to simulate human intelligence [47]. AI introduces new concepts and solutions to address complex challenges [48]. ML involves algorithms and statistical models designed to learn from examples and observations. In this way, ML can recognize and infer patterns, enabling it to execute tasks without requiring explicit instructions from a human operator [47,49]. ML includes three types of algorithms: (i) unsupervised, which finds patterns without external guidance; (ii) supervised, which requires human input to help the machine learn; and (iii) reinforcement learning, which uses rewards and punishments to create a specific operational strategy [48]. ML-based techniques have proven successful in various fields, including biomedical and medical applications [50]. Neural networks are a common type of supervised ML that has been widely used in the medical field.

During training, the data flow through an iterative network where weights are constantly adjusted, enabling the neural network to enhance its classification capacity [47]. A visual representation can be found in Supplementary Materials' Figure S1. DL with multiple layers of neurons has emerged as the leading AI technique for processing complex image data. DL utilizes artificial neural networks to map image inputs and diagnostic outputs without the explicit involvement of human engineering. It should be noted that convolutional neural networks (CNNs) are a particular type of DL that have been proven successful in classifying image data. The use of CNNs for image classification has become increasingly popular due to advancements in computer-based methods like AlexNet [47,51], which utilize transfer learning from pre-trained networks to learn from images in datasets [34]. Classifying data with CNNs is an easy, cost-effective, and computationally efficient process. In medicine, CNNs have primarily been used for visual diagnosis in dermatology, radiology, and pathology [47].

There are over 2000 skin conditions that impact one-third of the global population, constituting a significant health care burden [52]. Dermatology has the potential to benefit from the use of DL to enhance patient care. Thus, the combination of AI and hardware-based methods can boost dermatologists' abilities and is essential in improving access to and the quality of dermatological care. This provides real-time diagnostic support during clinical consultations [51]. Choy et al. [52] analyzed the most common skin conditions, including acne, psoriasis, eczema, rosacea, and urticaria. The DL algorithms have an estimated accu-

racy rate of around 90% for diagnosing these diseases [52]. Srinivasu et al. [21] developed a process utilizing various DL algorithms to classify non-infectious skin diseases. Their study showed that MobileNet V2 had greater accuracy on lightweight computing devices. Goceri [23] used MobileNet V2 in a mobile phone application with a user-friendly interface and demonstrated that the proposed method accurately diagnosed dermatological diseases with 94.76% accuracy. AlSuwaidan [53] evaluated the performance of six CNNs (VGG16, EfficientNet, InceptionV3, MobileNet, NasNet and ResNet50) for the three most common dermatological conditions (eczema, atopic dermatitis, and psoriasis) in the Middle East, and MobileNet had the highest accuracy (95.7%). Li et al. [54] also showed the performance of different CNNs for the diagnosis of actinic keratosis with an accuracy of about 92%. Bisla et al. [55] employed DL for melanoma classification, displaying superior performance compared to common baseline methods. Finally, Nourledeen et al. [27] employed the YOLOv5 model for identifying CL and obtained a mean precision of 70% in pinpointing skin lesions. Thieme et al. [56] developed a CNN to identify the characteristics of skin lesions caused by monkey pox, achieving a sensitivity of approximately 90%. These data suggest that DL mobile systems may assist clinicians in accurately diagnosing skin lesions. Additionally, AI systems could be a way to speed up the diagnostic process and reduce the high daily workload, and DL approaches have provided highly satisfactory results in image analysis to achieve this goal [57].

Other studies have used DL models for dermatological diagnosis and have performed equally or better than dermatologists, e.g., Han et al. [19]. Currently, there are no studies that have analyzed pictures of CL lesions in comparison with other skin diseases caused by fungal infections, bacterial infections, and non-infectious diseases by applying a pre-trained neural network such as AlexNet. In this study, we showed that the DL network has an average accuracy of 95.04% for identifying pictures of CL lesions from other skin diseases. Therefore, the performance of the algorithm used in our study will help to improve the diagnosis of CL based on pictures of skin lesions.

We observed that leprosy, ecthyma and basal cell carcinoma (BCC) were frequently confused with CL when using AlexNet. CL lesions can have diverse clinical manifestations, with atypical morphologies, which may be associated with several factors, such as pathogenicity, virulence, and host immunity [14]. Differential diagnosis still represents a challenge, as other diseases can manifest in a similar way to CL, such as BCC, leprosy, ecthyma and malignant neoplasm. Furthermore, other skin diseases that could be confused with CL include chromomycosis, blastomycosis, cutaneous tuberculosis, squamous cell carcinoma, erysipelas, herpes zoster, cutaneous lymphoma, tertiary syphilis, leprosy, paracoccidiomycosis, lupus, granulomatous rosacea, and persistent reactions to arthropod bites, among others [10–12,56]. Therefore, CL is called “the great imitator”, as it can resemble several types of dermatoses [14]. It is well established that when multiple comparisons are performed, an increase in the amount of type 1 errors is expected [58]. By the same logic, when comparing multiple categories, it is expected that only by chance will some categories exhibit a higher rate of false positives than others. The presence of various diseases in the “other dermatoses” category results in few images of each disease type, which can complicate the training of the AI algorithm for leprosy, ecthyma, and BCC, increasing the likelihood that a particular disease will have a high false-positive rate.

Although our study demonstrates the potential to differentiate CL from other skin lesions via DL, it also has limitations. The Leishmaniasis Clinic of the University Hospital of Brasilia, despite being a reference center for CL, may have a different patient profile than primary care patients, which may affect the accuracy of the test [59]. Therefore, the results may not be completely applicable to the general population, as the profile of those served in basic care is different. To overcome this situation, sampling could be carried out that includes primary care patients. Another limitation is the number of pictures for the two groups used as a database, especially for other skin diseases, as there is a lower proportion of patients referred to the University Hospital of Brasilia and diagnosed with other dermatoses during the years the database was constructed, since the clinic is a refer-

ence for CL diagnosis. However, collaborations with other dermatology centers to increase the database of other dermatoses may be a possible solution. It is important to expand the database to include CL lesions and other skin diseases caused by various *Leishmania* species found in other countries, as our study indicates that the lesions are predominantly caused by *L. braziliensis*, and in some cases, by *L. amazonensis* and *L. guyanensis* [60,61]. It is noteworthy that Old World CL lesions differ from New World lesions, which may progress to hyperkeratotic plaques. When caused by *L. tropica* or *L. major*, the wounds can self-heal within a year and may leave scars. However, if caused by *L. aethiopica*, healing may take years and result in severe mucocutaneous oronasal leishmaniasis. New World CL lesions caused by *L. mexicana* are less severe and heal faster compared to lesions caused by the *Leishmania* (*Viannia*) species, which result in more severe forms of ulcerative and mucocutaneous leishmaniasis [3]. We anticipate that the polymorphism of skin lesion pictures in the database could enable the AI algorithm to distinguish CL lesions caused by various species of *Leishmania*. Recently, an AI-based system was developed to detect *Leishmania* parasites in microscopic images [62]. Therefore, we believe that AI can enhance the diagnosis of CL by processing macroscopic and microscopic images of skin lesions and parasites, respectively. These innovations could improve the parasitological diagnosis of CL, which remains the gold standard due to its high specificity. Furthermore, in our work, we built a DL model using pictures as the unit of analysis and, therefore, our results may not be extrapolated to conclude the diagnosis. To resolve this limitation, we will carry out a cohort study that uses the model constructed here to evaluate the accuracy of this instrument in real life. Furthermore, variations in image acquisition and quality, such as zoom, focus, lighting, and the presence of hair, pose challenges to the implementation of AI in clinical settings. The quality and field of view of the skin lesion image can have a significant impact on accuracy, and performance tends to improve in the absence of hair [55]. To overcome this challenge, we can include high- and low-quality images in our database. We use up to 10 pictures of each patient lesion, which poses a problem with non-independent data. We have two approaches to overcome this limitation: (1) increase the image database to use only one image of each lesion, or (2) apply generalized mixed models [37,63] to deal with problems of non-independence and convergence in the image database. Although manual image segmentation (cropping) was used in the model presented here, automating the segmentation and resizing processes are essential to create an application that health care professionals can easily use. This automation will be implemented in the ongoing study cohort.

5. Conclusions

Our study found that AlexNet has an accuracy of 95% in identifying CL lesions, which is a highly significant value for this complex diagnosis. Therefore, automated CL identification through AlexNet has the potential to assist clinicians in diagnosing skin lesions. These findings contribute to the development of a mobile application to support in the diagnosis of CL in health care services. Finally, our study represents an advancement in the application of DL as a new diagnostic tool in CL, with potential for application in the diagnosis of other infectious skin diseases.

The automated diagnosis of CL lesions using AI can help health care professionals by improving the accuracy of clinical assessments in real time. Therefore, AI can be a valuable tool to benefit health services by facilitating a differential diagnosis of skin lesions. In settings where professionals are not directly involved in the development of ML techniques, trained technicians can form a team to assist experts in creating automated diagnostic tools. This approach combines clinical research focused on diagnosis, treatment, and prevention with technological research involving AI and mobile application development. This collaborative effort has the potential to contribute to the early diagnosis and timely treatment of CL.

Supplementary Materials: The following supporting information can be downloaded at: <https://www.mdpi.com/article/10.3390/biomedicines12010012/s1>, Figure S1: AlexNet network training progress.

Author Contributions: Conceptualization, R.G.-G., J.F.d.C.L. and D.H.B.; methodology, J.F.d.C.L., N.S.T. and V.L.d.M.; validation, J.F.d.C.L. and D.H.B.; formal analysis, J.F.d.C.L.; investigation, J.F.d.C.L.; writing—original draft preparation, J.F.d.C.L. and R.G.-G.; writing—review and editing, J.F.d.C.L. and R.G.-G. All authors have read and agreed to the published version of the manuscript.

Funding: This research was partially funded by the Postgraduate Program in Tropical Medicine at the University of Brasília. JFCL received a grant from the Coordination for the Improvement of Higher Education Personnel (CAPES, Brazil; Financial Code 001). RGG received funding from the National Council for Scientific and Technological Development (CNPq, Brazil, award number 314892/2021-4) and DHB received funding from National Council for Scientific and Technological Development (CNPq, Brazil, award number 409117/2023-4).

Institutional Review Board Statement: This study was conducted in accordance with the Declaration of Helsinki and approved by the ethics committee of the Faculty of Medicine.

Informed Consent Statement: Patient consent was waived due to anonymization of patients' data and absence of interventions that could harm patients.

Data Availability Statement: The data presented in this study are available on request from the corresponding author. The data are not publicly available due to ethical restrictions.

Acknowledgments: We are grateful to the doctors and residents of the dermatology outpatient clinic at the University Hospital of Brasilia for their patient management. We thank Gerson Oliveira Penna for his useful suggestions.

Conflicts of Interest: The authors declare no conflict of interest. The funders had no role in the design of the study; in the collection, analyses, or interpretation of data; in the writing of the manuscript; or in the decision to publish the results.

References

1. Mathison, B.A.; Bradley, B.T. Review of the Clinical Presentation, Pathology, Diagnosis, and Treatment of Leishmaniasis. *Lab. Med.* **2023**, *54*, 363–371. [[CrossRef](#)] [[PubMed](#)]
2. Nazzaro, G.; Rovaris, M.; Veraldi, S. Leishmaniasis: A disease with many names. *JAMA Dermatol.* **2014**, *150*, 1204. [[CrossRef](#)] [[PubMed](#)]
3. Burza, S.; Croft, S.L.; Boelaert, M. Leishmaniasis. *Lancet* **2018**, *392*, 951–970. [[CrossRef](#)] [[PubMed](#)]
4. Alvar, J.; Vélez, I.D.; Bern, C.; Herrero, M.; Desjeux, P.; Cano, J.; Jannin, J.; Boer, M.D.; WHO Leishmaniasis Control Team. Leishmaniasis worldwide and global estimates of its incidence. *PLoS ONE* **2012**, *7*, e35671. [[CrossRef](#)] [[PubMed](#)]
5. Abadías-Granado, I.; Diago, A.; Cerro, P.A.; Palma-Ruiz, A.M.; Gilaberte, Y. Leishmaniasis cutánea y mucocutánea. *Actas Dermosifiliogr.* **2021**, *112*, 601–618. [[CrossRef](#)] [[PubMed](#)]
6. Goto, H.; Lindoso, J.A.L. Cutaneous and mucocutaneous leishmaniasis. *Infect. Dis. Clin.* **2012**, *26*, 293–307. [[CrossRef](#)] [[PubMed](#)]
7. Showler, A.J.; Boggild, A.K. Cutaneous leishmaniasis in travellers: A focus on epidemiology and treatment in 2015. *Curr. Infect. Dis. Rep.* **2015**, *17*, 37. [[CrossRef](#)] [[PubMed](#)]
8. Aronson, N.E.; Joya, C.A. Cutaneous leishmaniasis: Updates in diagnosis and management. *Infect. Dis. Clin.* **2019**, *33*, 101–117. [[CrossRef](#)]
9. Leishmaniasis. Available online: <https://www.who.int/news-room/fact-sheets/detail/leishmaniasis> (accessed on 24 July 2023).
10. Mitropoulos, P.; Konidas, P.; Durkin-konidas, M. New World cutaneous leishmaniasis: Updated review of current and future diagnosis and treatment. *J. Am. Acad. Dermatol.* **2010**, *63*, 309–322. [[CrossRef](#)]
11. Handler, M.Z.; Patel, P.A.; Kapila, R.; Al-Qubati, Y.; Schwartz, R.A. Cutaneous and mucocutaneous leishmaniasis: Differential diagnosis, diagnosis, histopathology, and management. *J. Am. Acad. Dermatol.* **2015**, *73*, 911–926. [[CrossRef](#)]
12. Tirelli, F.; Vernal, S.; Roselino, A.M. Final diagnosis of 86 cases included in differential diagnosis of American tegumentary leishmaniasis in a Brazilian sample: A retrospective cross-sectional study. *An. Bras. Dermatol.* **2017**, *92*, 642–648. [[CrossRef](#)] [[PubMed](#)]
13. Vink, M.M.; Nahzat, S.M.; Rahimi, H.; Buhler, C.; Ahmadi, B.A.; Nader, M.; Zazai, F.R.; Yousufzai, A.S.; Loenen, M.V.; Schallig, H.D.F.H.; et al. Evaluation of point-of-care tests for cutaneous leishmaniasis diagnosis in Kabul, Afghanistan. *EBioMed* **2018**, *37*, 453–460. [[CrossRef](#)] [[PubMed](#)]
14. Gurel, M.S.; Tekin, B.; Uzun, S. Cutaneous leishmaniasis: A great imitator. *Clin. Dermatol.* **2020**, *38*, 140–151. [[CrossRef](#)] [[PubMed](#)]
15. Doupe, P.; Faghmous, J.; Basu, S. Machine learning for health services researchers. *Val. Health* **2019**, *22*, 808–815. [[CrossRef](#)] [[PubMed](#)]

16. Leha, A.; Hellenkamp, K.; Unsöld, B.; Mushemi-Blake, S.; Shah, A.M.; Hasenfuß, G.; Seidler, T. A machine learning approach for the prediction of pulmonary hypertension. *PLoS ONE* **2019**, *14*, e0224453. [[CrossRef](#)] [[PubMed](#)]
17. Sippy, R.; Farrell, D.F.; Lichtenstein, D.A.; Nightingale, R.; Harris, M.A.; Toth, J.; Hantztidiamantis, P.; Usher, N.; Aponte, C.C.; Aguilar, J.B.; et al. Severity Index for Suspected Arbovirus (SISA): Machine learning for accurate prediction of hospitalization in subjects suspected of arboviral infection. *PLoS Negl. Trop. Dis.* **2020**, *14*, e0007969. [[CrossRef](#)] [[PubMed](#)]
18. Bamorovat, M.; Sharifi, I.; Rashedi, E.; Shafii, A.; Sharifi, F.; Khosravi, A.; Tahmouresi, A. A novel diagnostic and prognostic approach for unresponsive patients with anthroponotic cutaneous leishmaniasis using artificial neural networks. *PLoS ONE* **2021**, *16*, e0250904. [[CrossRef](#)]
19. Han, S.S.; Moon, I.J.; Lim, W.; Suh, I.S.; Lee, S.Y.; Na, J.I.; Kim, S.H.; Chang, S.E. Keratinocytic skin cancer detection on the face using region-based convolutional neural network. *JAMA Dermatol.* **2020**, *156*, 29–37. [[CrossRef](#)]
20. Tschandl, P.; Rinner, C.; Apalla, Z.; Argenziano, G.; Codella, N.; Halpern, A.; Janda, M.; Lallas, A.; Longo, C.; Malvehy, J.; et al. Human–computer collaboration for skin cancer recognition. *Nat. Med.* **2020**, *26*, 1229–1234. [[CrossRef](#)]
21. Srinivasu, P.N.; SivaSai, J.G.; Ijaz, M.F.; Bhoi, A.K.; Kim, W.; Kang, J.J. Classification of skin disease using deep learning neural networks with MobileNet V2 and LSTM. *Sensors* **2021**, *21*, 2852. [[CrossRef](#)]
22. De, A.; Sarda, A.; Gupta, S.; Das, S. Use of artificial intelligence in dermatology. *Indian J. Dermatol.* **2020**, *65*, 352–357. [[CrossRef](#)] [[PubMed](#)]
23. Goceri, E. Diagnosis of skin diseases in the era of deep learning and mobile technology. *Comput. Biol. Med.* **2021**, *134*, 104458. [[CrossRef](#)] [[PubMed](#)]
24. Barbieri, R.R.; Xu, Y.; Setian, L.; Souza-Santos, P.T.; Trivedi, A.; Cristofono, J.; Bhering, R.; White, K.; Sales, A.M.; Miller, G. Reimagining leprosy elimination with AI analysis of a combination of skin lesion pictures with demographic and clinical data. *Lancet Reg. Health Am.* **2022**, *9*, 1–9. [[CrossRef](#)]
25. Jones, O.T.; Matin, R.N.; Van der Schaar, M.; Prathivadi Bhayankaram, K.; Ranmuthu, C.K.I.; Islam, M.S.; Behiyat, D.; Boscott, R.; Calanzani, N.; Emery, J.; et al. Artificial intelligence and machine learning algorithms for early detection of skin cancer in community and primary care settings: A systematic review. *Lancet Dig. Health* **2022**, *4*, e466–e476. [[CrossRef](#)] [[PubMed](#)]
26. Smak Gregoor, A.M.; Sangers, T.E.; Bakker, L.J.; Hollestein, L.; Uyl-de Groot, C.A.; Nijsten, T.; Wakkee, M. An artificial intelligence based app for skin cancer detection evaluated in a population based setting. *NPJ Dig. Med.* **2023**, *6*, 90. [[CrossRef](#)] [[PubMed](#)]
27. Noureldeen, A.M.; Masoud, K.S.; Almakzoom, O.A. Deep learning model for Cutaneous leishmaniasis detection and classification using Yolov5. *Afr. J. Adv. Pure Appl. Sci.* **2023**, *2*, 270–280.
28. Litjens, G.; Kooi, T.; Bejnordi, B.E.; Setio, A.A.A.; Ciompi, F.; Ghafoorian, M.; Van der Laak, J.A.W.M.; Van Ginneken, B.; Sánchez, C.I. A Survey on Deep Learning in Medical Image Analysis. *Med. Imag. Anal.* **2017**, *42*, 60–88. [[CrossRef](#)] [[PubMed](#)]
29. Latif, J.; Xiao, C.; Imran, A.; Tu, S. Medical imaging using machine learning and deep learning algorithms: A Review. In Proceedings of the 2019 2nd International Conference on Computing, Mathematics and Engineering Technologies (iCoMET), Sukkur, Pakistan, 30–31 January 2019; pp. 1–5. [[CrossRef](#)]
30. Souza, E.P.D.; Gomes, C.M.; Barroso, D.H.; Miranda, V.L.D.; Gurgel-Gonçalves, R. Aplicações do Deep Learning para diagnóstico de doenças e identificação de insetos vetores. *Saúde Debat.* **2020**, *43*, 147–154. [[CrossRef](#)]
31. Gomes, C.M.; Paula, N.A.; Morais, O.O.; Soares, K.A.; Roselino, A.M.; Sampaio, R.N. Complementary exams in the diagnosis of American tegumentary leishmaniasis. *An. Bras. Dermatol.* **2014**, *89*, 701–709. [[CrossRef](#)]
32. Pinheiro, A.B.S.; Kurizky, P.S.; Ferreira, M.D.F.; Mota, M.A.D.S.; Ribeiro, J.S.; Oliveira Filho, E.Z.D.; Souza, C.A.; Barroso, D.H.; Sampaio, R.N.R.; Gomes, C.M. The accuracy of the Montenegro skin test for leishmaniasis in PCR-negative patients. *Rev. Soc. Bras. Med. Trop.* **2020**, *53*, e20190433. [[CrossRef](#)]
33. Barroso, D.H.; Gonçalves, R.T.; Barbosa, J.S.; Motta, J.D.O.C.; Freire, G.S.M.; Gomes, C.M.; Sampaio, R.N.R. Meglumine antimoniate was associated with a higher cure rate than liposomal amphotericin B in the treatment of American tegumentary leishmaniasis: A retrospective cohort study from a *Leishmania braziliensis*-endemic area. *Front. Cell. Infect. Microbiol.* **2022**, *12*, 1426. [[CrossRef](#)] [[PubMed](#)]
34. Tegumentary Leishmaniasis Surveillance Manual. Available online: https://bvsm.s.saude.gov.br/bvs/publicacoes/manual_vigilancia_leishmaniose_tegumentar.pdf (accessed on 30 August 2023).
35. Krizhevsky, A.; Sutskever, I.; Hinton, G.E. ImageNet classification with deep convolutional neural networks. *Comm. ACM* **2017**, *60*, 84–90. [[CrossRef](#)]
36. Motta, D.; Santos, A.Á.B.; Winkler, I.; Machado, B.A.S.; Pereira, D.A.D.I.; Cavalcanti, A.M.; Fonseca, E.O.L.; Kirchner, F.; Badaró, R. Application of convolutional neural networks for classification of adult mosquitoes in the field. *PLoS ONE* **2019**, *14*, e0210829. [[CrossRef](#)] [[PubMed](#)]
37. Miranda, V.L.; Souza, E.P.; Bambil, D.; Khalighifar, A.; Peterson, A.T.; Nascimento, F.A.O.; Gurgel-Gonçalves, R.; Abad-Franch, F. Cellphone-picture based automated identification of Chagas disease vectors: Effects of bug genus and image orientation on the performance of five machine-learning algorithms. *Ecol. Inf.* **2023**, *79*, e102430. [[CrossRef](#)]
38. Hamida, A.B.; Devanne, M.; Weber, J.; Truntzer, C.; Derangère, V.; Ghiringhelli, F.; Forestier, G.; Wemmert, C. Deep learning for colon cancer histopathological images analysis. *Comput. Biol. Med.* **2021**, *136*, 104730. [[CrossRef](#)]
39. Kumar, L.S.; Hariharasitaraman, S.; Narayanasamy, K.; Thinakaran, K.; Mahalakshmi, J.; Pandimurugan, V. AlexNet approach for early stage Alzheimer’s disease detection from MRI brain images. *Mater. Today Proc.* **2022**, *51*, 58–65. [[CrossRef](#)]

40. Newcombe, R.G. Two-sided confidence intervals for the single proportion: Comparison of seven methods. *Stat Med.* **1998**, *17*, 857–872. [CrossRef]
41. RStudio Team. RStudio: Integrated Development for R. RStudio, PBC, Boston, MA. RStudio 2023.03.1.446. 2022. Available online: <https://posit.co/products/open-source/rstudio/> (accessed on 14 August 2023).
42. R Core Team. Available online: <https://www.Rproject.org/> (accessed on 30 August 2023).
43. Package ‘Hmisc’: Harrell Miscellaneous. Available online: <http://www.who.int/mediacentre/factsheets/fs340/en/> (accessed on 30 August 2023).
44. Abad-Franch, F. Chagas disease diagnosis and cure assessment: Getting formally hierarchical about a naturally hierarchical problem. *PLoS Negl. Trop. Dis.* **2020**, *14*, e0008751. [CrossRef]
45. Bossuyt, P.M.M.; Reitsma, J.B.; Linnet, K.; Moons, K.G.M. Beyond diagnostic accuracy: The clinical utility of diagnostic tests. *Clin. Chem.* **2012**, *58*, 1636–1643. [CrossRef]
46. Borges, L. Medidas de acurácia diagnóstica na pesquisa cardiovascular. *Int. J. Cardiovasc. Sci.* **2016**, *29*, 218–222. [CrossRef]
47. Du-Harpur, X.; Watt, F.M.; Luscombe, N.M.; Lynch, M.D. What is AI? Applications of artificial intelligence to dermatology. *Br. J. Dermatol.* **2020**, *183*, 423–430. [CrossRef] [PubMed]
48. Hamet, P.; Tremblay, J. Artificial intelligence in medicine. *Metabolism* **2017**, *69*, S36–S40. [CrossRef] [PubMed]
49. Janiesch, C.; Zschech, P.; Heinrich, K. Machine learning and deep learning. *Electron. Mark.* **2021**, *31*, 685–695. [CrossRef]
50. El Naqa, I.; Murphy, M.J. What is machine learning? In *Machine Learning in Radiation Oncology*; Springer: Cham, Switzerland, 2015; pp. 3–11. [CrossRef]
51. Young, A.T.; Xiong, M.; Pfau, J.; Keiser, M.J.; Wei, M.L. Artificial intelligence in dermatology: A primer. *J. Investig. Dermatol.* **2020**, *140*, 1504–1512. [CrossRef] [PubMed]
52. Choy, S.P.; Kim, B.J.; Paolino, A.; Tan, W.R.; Lim, S.M.L.; Seo, J.; Tan, S.P.; Francis, L.; Tsakok, T.; Simpson, M.; et al. Systematic review of deep learning image analyses for the diagnosis and monitoring of skin disease. *NPJ Digit. Med.* **2023**, *6*, 180. [CrossRef] [PubMed]
53. AlSuwaidan, L. Deep Learning Based Classification of Dermatological Disorders. *Biomed. Eng. Comput. Biol.* **2023**, *14*, 11795972221138470. [CrossRef] [PubMed]
54. Li, X.; Desrosiers, C.; Liu, X. Deep neural forest for out-of-distribution detection of skin lesion images. *IEEE J. Biomed. Health Inform.* **2023**, *27*, 157–165. [CrossRef] [PubMed]
55. Bisla, D.; Choromanska, A.; Berman, R.S.; Stein, J.A.; Polsky, D. Towards automated melanoma detection with deep learning: Data purification and augmentation. *arXiv* **2019**, arXiv:1902.06061.
56. Thieme, A.H.; Zheng, Y.; Machiraju, G.; Sadee, C.; Mittermaier, M.; Gertler, M.; Salinas, J.L.; Srinivasan, K.; Gyawali, P.; Carrillo-Perez, F.; et al. A deep-learning algorithm to classify skin lesions from mpox virus infection. *Nat. Med.* **2023**, *29*, 738–747. [CrossRef]
57. Marletta, S.; L’Imperio, V.; Eccher, A.; Antonini, P.; Santonicco, N.; Girolami, I.; Dei Tos, A.P.; Sbaraglia, M.; Pagni, P.; Brunelli, M.; et al. Artificial intelligence-based tools applied to pathological diagnosis of microbiological diseases. *Pathol. Res. Pract.* **2023**, *243*, 154362. [CrossRef]
58. Motulsky, H. *Intuitive Biostatistics: A Nonmathematical Guide to Statistical Thinking*, 3rd ed.; Oxford University Press: New York, NY, USA, 2014.
59. Al-Khateeb, B. Primary health care and family physicians provide frontline care to the dermatology patients during the era of COVID-19: Recommendations and future directions. *J. Family Med. Prim. Care* **2020**, *9*, 5862. [CrossRef]
60. Barroso, D.H.; Falcão, S.D.A.C.; Motta, J.D.O.C.D.; Sevilha dos Santos, L.; Takano, G.H.S.; Gomes, C.M.; Favali, C.B.F.; Lima, B.D.; Sampaio, R.N.R. PD-L1 may mediate T-cell exhaustion in a case of early diffuse leishmaniasis caused by *Leishmania (L.) amazonensis*. *Front. Immunol.* **2018**, *9*, 1021. [CrossRef]
61. Carvalho, B.C.; Vital, T.; Osiro, J.; Gomes, C.M.; Noronha, E.; Dallago, B.; Rosa, A.C.; Carvalho, J.L.; Hagström, L.; Hecht, M.; et al. Multiparametric analysis of host and parasite elements in new world tegumentary leishmaniasis. *Front. Cell. Infect. Microbiol.* **2022**, *12*, 956112. [CrossRef]
62. Zare, M.; Akbarialiabad, H.; Parsaei, H.; Asgari, Q.; Alinejad, A.; Bahreini, M.S.; Hosseini, S.H.; Ghofrani-Jahromi, M.; Shahriari-rad, R.; Amirmoezzi, Y.; et al. A machine learning-based system for detecting leishmaniasis in microscopic images. *BMC Infect. Dis.* **2022**, *22*, 48. [CrossRef]
63. Bolker, B.M.; Brooks, M.E.; Clark, C.J.; Geange, S.W.; Poulsen, J.R.; Stevens, M.H.H.; White, J.S.S. Generalized linear mixed models: A practical guide for ecology and evolution. *Trends Ecol. Evol.* **2009**, *24*, 127–135. [CrossRef]

Disclaimer/Publisher’s Note: The statements, opinions and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of MDPI and/or the editor(s). MDPI and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions or products referred to in the content.