

USO DE MODELOS DE APRENDIZADO DE MÁQUINA NO DIAGNÓSTICO PARASITOLÓGICO: UMA REVISÃO DE ESCOPO

USE OF MACHINE LEARNING MODELS IN PARASITOLOGICAL DIAGNOSIS: A SCOPING REVIEW



e-ISSN 2525-5851
Centro de Ciências
Médicas/UFPB

RESUMO

Objetivo: O objetivo deste estudo foi identificar e analisar os principais modelos de aprendizado de máquina empregados no diagnóstico de parasitas de interesse médico, com ênfase em suas aplicações no contexto do diagnóstico laboratorial automatizado. **Método:** Realizou-se uma revisão de escopo seguindo as diretrizes do PRISMA-ScR. As buscas foram conduzidas nas bases de dados MEDLINE/PubMed (n=87), Embase (Elsevier) (n=162) e Scopus (Elsevier) (n=79). Foram incluídos estudos publicados entre 2019 e 2024, disponíveis na íntegra, redigidos em inglês, português ou espanhol. Os critérios de inclusão abrangeram artigos que abordassem a aplicação de técnicas de aprendizado de máquina no diagnóstico de parasitas humanos com relevância médica. **Resultados:** Do total de estudos identificados, 12 atenderam aos critérios de inclusão e foram analisados nesta revisão. Os artigos selecionados evidenciam o uso crescente de algoritmos de aprendizado de máquina em diferentes etapas do diagnóstico laboratorial, especialmente no reconhecimento e classificação automática de imagens microscópicas de parasitas intestinais e urogenitais. Os modelos mais utilizados incluíram redes neurais convolucionais (CNN), máquinas de vetor de suporte (SVM) e árvores de decisão, entre outros. **Conclusão:** Os estudos revisados destacam que as ferramentas baseadas em aprendizado de máquina, especialmente aquelas voltadas para segmentação de imagens e detecção de objetos, apresentam resultados promissores no diagnóstico de helmintos e protozoários. Essas tecnologias demonstram desempenho semelhante ao da análise microscópica manual tradicional, com elevadas taxas de acurácia, sensibilidade e especificidade, representando um avanço significativo no apoio ao diagnóstico parasitológico automatizado.

Palavras-chave: Parasitologia; Aprendizado de Máquina; Contagem de Ovos de Parasitas; Processamento de Imagem Assistida por Computador.

Submetido em: 11/04/2025
Aceito em: 30/06/2025
Publicado em: 03/07/2025

João Kasprowicz
Mestrando do Programa de
Pós Graduação em
Informática em Saúde
(PPGINFOS) da Universidade
Federal de Santa Catarina
(UFSC)
joao.kasprowicz@univali.br

Halan Bacca
Mestrando do PPGINFOS da
Universidade Federal de
Santa Catarina (UFSC)
halanbacca@outlook.com

Daniel da Silva Rosa
Especializando em Inovação
e Tecnologia Instituto
Federal de Santa Catarina
(IFSC)
daniel100262@hotmail.com

Como citar este artigo:

Kasprowicz J, Bacca H, Rosa DS. Uso de modelos de aprendizado de máquina no diagnóstico parasitológico: uma revisão de escopo. Revista Medicina & Pesquisa 2024; 5(3): 9-18

ABSTRACT

Objective: This study aimed to identify and analyze the main machine learning models employed in the diagnosis of medically relevant parasites, with an emphasis on their applications in the context of automated laboratory diagnosis.

Method: A scoping review was conducted following the PRISMA-ScR guidelines. Searches were carried out in the MEDLINE/PubMed (n=87), Embase (Elsevier) (n=162), and Scopus (Elsevier) (n=79) databases. Studies published between 2019 and 2024 were included, provided they were available in full text and written in English, Portuguese, or Spanish. Inclusion criteria encompassed articles addressing the application of machine learning techniques in the diagnosis of human parasites of medical importance.

Results: Of the total studies identified, 12 met the inclusion criteria and were analyzed in this review. The selected articles highlight the growing use of machine learning algorithms in various stages of laboratory diagnosis, particularly in the automatic recognition and classification of microscopic images of intestinal and urogenital parasites. The most commonly used models included convolutional neural networks (CNNs), support vector machines (SVMs), and decision trees, among others.

Conclusion: The reviewed studies underscore that machine learning-based tools, especially those focused on image segmentation and object detection, show promising results in the diagnosis of helminths and protozoa. These technologies demonstrate performance comparable to traditional manual microscopic analysis, with high accuracy, sensitivity, and specificity rates, representing a significant advancement in support of automated parasitological diagnosis.

Keywords: Parasitology; Machine Learning; Parasite Egg Count; Image Processing, Computer-Assisted.

1 INTRODUÇÃO

Infecções intestinais parasitárias têm implicações graves para a saúde pública mundial, tanto em países desenvolvidos quanto em países subdesenvolvidos. De acordo com a Organização Mundial da Saúde (OMS), essas infecções afetam aproximadamente 24% da população global. Os sintomas mais comuns incluem diarreia, desnutrição, anemia, entre outros, sendo as crianças o grupo mais afetado. Entre as cerca de 100 espécies de parasitas intestinais conhecidas, algumas podem reproduzir-se diariamente, chegando a produzir até 200 mil ovos por dia [1].

O método padrão para identificação de ovos de parasitas intestinais é a pesquisa em amostras de fezes processadas e coradas com lugol, o que facilita a visualização ao microscópio. No entanto, esse método apresenta limitações, pois é demorado e depende significativamente da experiência do profissional responsável pela análise para garantir a pesquisa e a identificação correta [2].

Devido aos fatores mencionados, a análise apresenta variações relacionadas à coloração e à técnica utilizada. Nesse contexto, a automatização do processo de identificação de parasitas intestinais, por meio do uso de inteligência artificial, pode oferecer benefícios significativos, como maior precisão, rapidez e padronização. Entre as abordagens possíveis, destaca-se a aplicação de técnicas de visão computacional, que permitem a análise automatizada de imagens microscópicas das amostras de fezes. Essas técnicas utilizam algoritmos avançados para identificar padrões e características específicas dos ovos parasitários, reduzindo a subjetividade da análise manual e aumentando a eficiência do diagnóstico [3,4].

O objetivo desta revisão de escopo é mapear e sintetizar as evidências disponíveis sobre o uso de tecnologias, incluindo inteligência artificial e visão computacional, na identificação automatizada de parasitas. Busca-se identificar os avanços recentes, as limitações e as oportunidades de pesquisa nessa área, com foco em sua aplicação na melhoria do diagnóstico e da saúde pública.

MÉTODOS

Tipo de estudo

Trata-se de uma revisão de escopo que seguiu as etapas recomendadas pelo Instituto Joanna Briggs (JBI) e do checklist Preferred Reporting Items for Systematic reviews and Meta-Analyses extension for Scoping Reviews (PRISMA-ScR). Esse tipo de revisão busca

explorar os principais conceitos do tema em questão, averiguando a dimensão, o alcance e a natureza do estudo, condensando e publicando os dados, e, desta forma, apontando as lacunas de pesquisas existentes [5].

Questão de pesquisa

O desenho do estudo foi estruturado com base na metodologia População, Conceito e Contexto (PCC), visando orientar de forma sistemática a coleta de dados. A estratégia PCC, que serve como uma ferramenta mnemônica para identificar os elementos-chave do estudo, foi aplicada da seguinte maneira: a população foi definida como indivíduos submetidos a diagnósticos parasitológicos; o conceito abrange a aplicação de modelos de aprendizado de máquina no diagnóstico laboratorial; e o contexto inclui os cenários clínicos e laboratoriais voltados à detecção de parasitas. Dessa forma, a questão norteadora estabelecida foi: como os modelos de aprendizado de máquina têm sido aplicados no diagnóstico laboratorial automatizado de parasitas de interesse médico?

Crítérios de elegibilidade

Foram incluídos nesta revisão estudos primários quantitativos, qualitativos e de métodos mistos, disponíveis na íntegra nos idiomas português, inglês e espanhol. O período temporal considerado abrangeu os últimos 5 anos, de 2019 a 2024. Foram excluídos artigos que não atenderam aos critérios estabelecidos para o objetivo e a questão de pesquisa, bem como literatura cinzenta e aqueles não estavam disponíveis na íntegra mesmo com o acesso via Virtual Private Network (VPN) da Universidade Federal de Santa Catarina (UFSC), estudos em fase de projeto ou ainda sem resultados.

Estratégia de busca

A composição da estratégia de busca foi elaborada, sendo utilizados os operadores Booleanos AND e OR, no idioma inglês, português e espanhol e as combinações utilizando descritores consultados nos Descritores em Ciências de Saúde (DeCS) e Medical Subject Headings (MeSH). A busca ocorreu no mês de dezembro de 2024 e foram consultadas as seguintes bases de dados: United States National Library of Medicine/Medical Literature Analysis and Retrieval System Online (PubMed/MEDLINE), Embase (Elsevier) e Scopus (Quadro 1). Essas bases foram selecionadas por serem abrangentes, com ampla cobertura das publicações na área da saúde. O protocolo de pesquisa foi registrado no Open Science Framework (OSF) e está disponível através do Digital Object Identifier (DOI) 10.17605/OSF.IO/ZDFW9 e do endereço <https://osf.io/zdfw9/>.

Base de dados	Estratégia de busca
PubMed/MEDLINE	((("deep learning"[MeSH Terms] OR ("deep"[All Fields] AND "learning"[All Fields]) OR "deep learning"[All Fields] OR "machine learning"[MeSH Terms] OR ("machine"[All Fields] AND "learning"[All Fields]) OR "machine learning"[All Fields] OR "artificial intelligence"[MeSH Terms] OR ("artificial"[All Fields] AND "intelligence"[All Fields]) OR "artificial intelligence"[All Fields]) AND ("parasitology"[MeSH Terms] OR "parasitology"[All Fields] OR "parasite egg count"[MeSH Terms] OR ("parasite"[All Fields] AND "egg"[All Fields] AND "count"[All Fields]) OR "parasite egg count"[All Fields])) AND ("Image Processing, Computer-Assisted"[MeSH Terms] OR "Image Processing, Computer-Assisted"[All Fields] OR "microscopy"[MeSH Terms] OR "microscopy"[All Fields]) AND (y_5[Filter])
Embase (Elsevier)	('deep learning'/exp OR 'deep learning' OR (deep AND ('learning'/exp OR learning)) OR 'machine learning'/exp OR 'machine learning' OR (machine AND ('learning'/exp OR learning)) OR 'artificial intelligence'/exp OR 'artificial intelligence' OR (artificial AND ('intelligence'/exp OR intelligence))) AND ('parasitology'/exp OR parasitology OR 'parasite egg count'/exp OR 'parasite egg count' OR (parasite AND egg AND count)) AND ('image processing'/exp OR 'image processing' OR 'microscopy'/exp OR microscopy) AND [2019-2024]/py
Scopus (Elsevier)	("deep learning" OR "machine learning" OR "artificial intelligence" AND parasitology OR "parasite egg count" AND "image processing" OR microscopy) AND PUBYEAR > 2018 AND PUBYEAR < 2025 AND (LIMIT-TO (LANGUAGE, "English"))

PubMed/MEDLINE = United States National Library of Medicine/Medical Literature Analysis and Retrieval System Online

Seleção de estudos

O PRISMA-ScR foi adotado para guiar tanto o processo de inclusão quanto a apresentação dos resultados da seleção, seguindo as quatro etapas de identificação, triagem, elegibilidade e inclusão. A seleção dos estudos foi realizada por três revisores após a remoção das duplicatas. A extração dos dados da amostra final ocorreu utilizando uma planilha desenvolvida no Microsoft Excel®, o que proporcionou uma visualização clara e organizada

das informações extraídas dos estudos incluídos na revisão⁵.

A seleção dos artigos científicos foi realizada em três etapas. A primeira etapa resumiu-se à construção de uma cadeia de busca formada pela combinação dos descritores. Na segunda etapa, aplicaram-se os filtros para busca, como artigos publicados nos últimos cinco anos (2019-2024), bem como artigos em inglês, português e espanhol, os artigos foram selecionados de acordo com o título e resumo que se encaixavam na questão de pesquisa, posteriormente, armazenados em ordem sequencial em uma planilha do Microsoft Excel®.

Nesta etapa, obras repetidas foram verificadas. A partir dos artigos selecionados nas etapas anteriores, a terceira etapa foi executada por dois revisores, que efetuaram a leitura do resumo, da introdução e da conclusão de cada artigo para identificar a relevância deste para a pesquisa e se preenchia os critérios de inclusão ou exclusão.

Mapeamento e análise dos dados

Uma estratégia de extração de dados foi estabelecida e adaptada conforme o manual do JBI, com o objetivo de selecionar as seguintes informações relevantes: (1) caracterização dos estudos, incluindo: autor, periódico, ano, título e tipo de estudo; (2) aplicabilidade clínica; (3) tipo de tecnologia utilizada; e (4) principais resultados e limitações. Essas informações foram organizadas em quadros e acompanhadas de conteúdo narrativo, utilizando o Microsoft Excel®.

Aspectos éticos

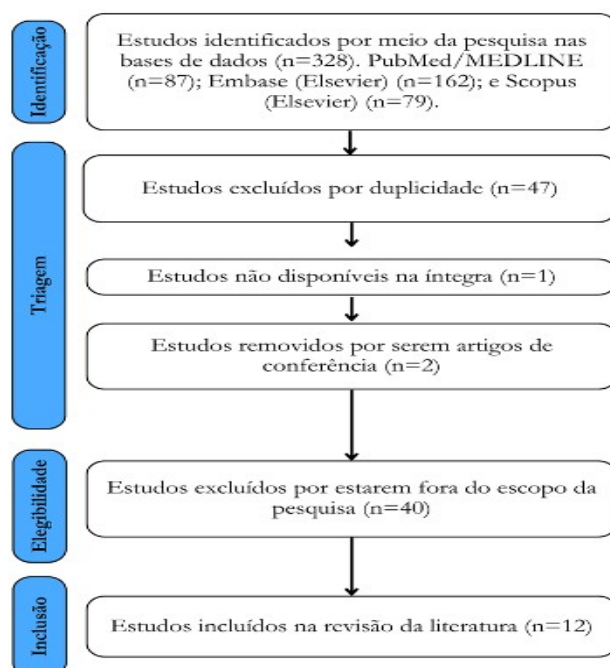
Por se tratar de um estudo de revisão de escopo, não há necessidade de submissão ao comitê de ética, pois não envolve coleta direta de dados de seres humanos ou experimentação.

3 RESULTADOS

Foram encontrados 328 estudos, distribuídos nas seguintes bases de dados: MEDLINE/PubMed (n=87), Embase (Elsevier) (n=162) e Scopus (Elsevier) (n=79).

O procedimento de busca e seleção dos estudos desta revisão está devidamente representado no fluxograma (Figura 1). Após esta etapa, 12 artigos foram selecionados, 47 artigos foram removidos por serem duplicados, 40 artigos foram removidos por estarem fora do escopo do tema, 1 artigo foi removido por não estar disponível na íntegra e 2 artigos foram removidos por serem artigos de conferência. Desta forma, os artigos foram salvos no formato Portable Document Format (PDF) para análise na íntegra. Durante a leitura dos artigos na íntegra levou-se em consideração o campo dos estudos, os resultados, a discussão e a conclusão.

Figura 1 - Fluxograma de buscas, conforme recomendações, adaptado do PRISMA-ScR. Florianópolis, SC, Brasil, 2024



Fonte: Os autores (2024)

Quadro 2 - Caracterização dos estudos incluídos na revisão de escopo. Florianópolis, SC, Brasil, 2024

Autoria	Título	Tipo	Conclusões
Lee, Chi-Ching <i>et al.</i> (2022) ⁽⁵⁾	Helminth egg analysis platform (HEAP): An opened platform for microscopic helminth egg identification and quantification based on the integration of deep learning architectures	Estudo de desenvolvimento e validação tecnológica	Ferramenta chamada HEAP, plataforma de código aberto que automatiza a identificação e quantificação de ovos de helmintos. Interface amigável e arquitetura distribuída, facilita o uso por técnicos, incentiva a colaboração e contribuições, e serve como banco de dados e recurso educacional
Oyibo <i>et al.</i> (2022) ⁽⁶⁾	Schistoscope: An Automated Microscope with Artificial Intelligence for Detection of Schistosoma haematobium Eggs in Resource-Limited Settings	Estudo de desenvolvimento tecnológico e validação experimental	O Schistoscope, um microscópio digital automatizado de baixo custo, demonstrou ser eficaz na detecção de ovos de <i>Schistosoma haematobium</i> , superando limitações da microscopia convencional. O dispositivo mostrou alta precisão, robustez e estabilidade, sendo adequado para programas de controle de esquistossomose em áreas endêmicas
Butploy, Kanarkard e Intapan (2021) ⁽⁷⁾	Deep Learning Approach for Ascaris lumbricoides Parasite Egg Classification	Estudo de desenvolvimento tecnológico	Modelo de rede neural convolucional desenvolvido para a classificação de ovos de <i>Ascaris lumbricoides</i> obteve uma acurácia de 93,33%. O modelo mostrou-se mais rápido e preciso que os métodos tradicionais de microscopia, oferecendo uma ferramenta auxiliar promissora para o diagnóstico médico, capaz de reduzir o tempo e a variabilidade nos processos de classificação de ovos parasitários
Dacal, Elena <i>et al.</i> (2021) ⁽⁸⁾	Mobile microscopy and telemedicine platform assisted by deep learning for the quantification of Trichuris trichiura infection	Estudo de desenvolvimento tecnológico	Desenvolvimento de um sistema completo para o diagnóstico remoto e automatizado de infecções por helmintos, focado principalmente em <i>Trichuris trichiura</i> . Alta taxa de precisão e boa recuperação, superando métodos convencionais em objetividade e eficiência
Kumar <i>et al.</i> (2023) ⁽⁹⁾	An Efficient and Effective Framework for Intestinal Parasite Egg Detection Using YOLOv5	Estudo de desenvolvimento tecnológico	Modelo de aprendizado profundo YOLOv5 para a detecção e classificação de ovos de helmintos, apresentando alta precisão e velocidade de detecção superando métodos manuais e tradicionais de detecção
Xu <i>et al.</i> (2024) ⁽¹⁰⁾	A lightweight deep-learning model for parasite egg detection in microscopy images	Estudo de desenvolvimento tecnológico	YAC-Net, modelo leve de aprendizado profundo baseado no YOLOv5n para detecção automatizada de ovos de parasitas em imagens microscópicas demonstrou superioridade em relação a outros modelos em termos de precisão, <i>F1-score</i> e mAP, mantendo-se leve e eficiente
Aldahoul <i>et al.</i> (2023) ⁽¹¹⁾	Parasitic egg recognition using convolution and attention network	Estudo de desenvolvimento tecnológico	CoAtNet, modelo para detecção de ovos de parasitas, baseado em rede neural convolucional e de atenção, apresenta desempenho superior quando comparado a EfficientNet, DenseNet e transformadores de visão
Lundin, Johan <i>et al.</i> (2024) ⁽¹²⁾	Diagnosis of soil-transmitted helminth infections with digital mobile microscopy and artificial intelligence in a resource-limited setting	Estudo de validação diagnóstica	Desenvolvimento e a avaliação de um sistema de diagnóstico digital para helmintos transmitidos pelo solo, usando microscopia móvel digital e inteligência artificial conduzido em uma clínica de saúde primária no Quênia que analisou 1.335 amostras de fezes de crianças em idade escolar
Ward <i>et al.</i> (2022) ⁽¹³⁾	Affordable artificial intelligence-based digital pathology for neglected tropical diseases: A proof-of-concept for the detection of soil-transmitted helminths and Schistosoma mansoni eggs in Kato-Katz stool thick smears	Estudo de prova de conceito	Prova de conceito de um dispositivo de patologia digital baseado em IA para a detecção automática de ovos de helmintos em amostras de fezes preparadas com a técnica de Kato-Katz, alcançando alta precisão (94,9% ± 0,8%) e <i>recall</i> (96,1% ± 2,1%)
Mathison, Blaine A <i>et al.</i> (2020) ⁽¹⁴⁾	Detection of Intestinal Protozoa in Trichrome-Stained Stool Specimens	Estudo de desenvolvimento tecnológico e	Desenvolvimento e a validação de uma rede neural convolucional para a detecção de protozoários intestinais em amostras de fezes, apresentando alta

	by Use of a Deep Convolutional Neural Network	validação inicial	precisão e sensibilidade cerca de cinco vezes maior que a microscopia manual
			Cont.
Maturana <i>et al.</i> (2024) ⁽¹⁵⁾	Development of an automated artificial intelligence-based system for urogenital schistosomiasis diagnosis using digital image analysis techniques and a robotized microscope	Estudo de validação tecnológica e prova de conceito	Desenvolvimento de um sistema automatizado e de baixo custo para o diagnóstico da esquistossomose urogenital, envolvendo o treinamento dos modelos de detecção de objetos (YOLOv5 e YOLOv8) e classificação binária (MobileNetv3Large, EfficientNetv2 e NasNetLarge). Os resultados indicam que o YOLOv5x apresenta alta precisão e <i>recall</i> quando comparado aos demais modelos, podendo se tornar uma alternativa acessível e eficiente à microscopia tradicional
Yang, Ariel <i>et al.</i> (2019) ⁽¹⁶⁾	KankaNet: An artificial neural network-based object detection smartphone application and mobile microscope as a point-of-care diagnostic aid for soil-transmitted helminthiasis	Estudo de validação tecnológica	Desenvolvimento de um sistema de diagnóstico assistido por IA, denominado KankaNet, que combina um microscópio conectado a um <i>smartphone</i> com um aplicativo de detecção de objetos baseado em redes neurais, demonstrando boa precisão diagnóstica

4 DISCUSSÃO

Esta revisão de escopo apresenta aplicações de inteligência artificial, especialmente técnicas de aprendizado profundo na identificação de parasitas de forma automatizada, os estudos incluídos convergem em torno de três eixos principais: desenvolvimento de plataformas automatizadas para detecção e quantificação de ovos de parasitas; uso de dispositivos de baixo custo e portabilidade para diagnóstico em campo; e aprimoramento da acurácia diagnóstica por meio de arquiteturas de rede sofisticadas.

Diversos estudos recentes têm explorado o uso de inteligência artificial (IA) e dispositivos de baixo custo para o diagnóstico automatizado de parasitoses, com foco especial em regiões endêmicas de *Schistosoma haematobium* e com recursos limitados. Entre as soluções desenvolvidas, destacam-se dispositivos portáteis baseados em redes neurais profundas capazes de identificar ovos de parasitas em amostras biológicas por meio de uma DNN baseada em U-Net. Em alguns casos, a integração com modelos de regressão linear permite estimativas precisas da carga parasitária, mesmo diante de imagens com ruídos ou baixa qualidade, demonstrando potencial para uso em campo [6].

Neste contexto, especificamente focado neste gênero de parasitas, os Schistosomas, autores desenvolveram um sistema baseado em IA para analisar imagens digitais de amostras de urina e detectar ovos de *Schistosoma haematobium*. O estudo utilizou 24 amostras de urina positivas e 8 negativas para *S. haematobium*. As imagens foram adquiridas com uma câmera integrada ao microscópio Leica ICC50W e um smartphone Samsung Galaxy S20 acoplado ao microscópio. As amostras foram pré-processadas e anotadas por profissionais de laboratório. Os autores treinaram e compararam diferentes modelos de redes neurais convolucionais (CNN), incluindo YOLOv5, YOLOv8, MobileNetv3Large, EfficientNetv2 e NasNetLarge. O YOLOv5x obteve o melhor desempenho na detecção de ovos, com precisão de 99,3%, revocação de 99,4% e F1-score de 99,3%. Já o NasNetLarge apresentou a maior precisão (85,6%) na detecção de eritrócitos e leucócitos nas imagens [7].

Além da detecção simples, algumas propostas vão além e apostam na diferenciação morfológica de estruturas parasitárias, como ovos férteis, inférteis e descorticados, exigindo maior refinamento dos modelos. Mesmo com conjuntos de dados mais limitados, essas abordagens vêm obtendo alta acurácia, o que reforça a ideia de que o ajuste fino dos algoritmos pode compensar a escassez de amostras.

Em linha com esse avanço, pesquisadores desenvolveram um protótipo baseado em uma CNN para a detecção de ovos de *Ascaris lumbricoides*, alcançando uma precisão de 93,33%. A proposta se destaca pelo foco na diferenciação entre tipos de ovos (fértil, infértil e descorticado), o que requer um modelo mais refinado, com capacidade de discriminação morfológica. Embora o conjunto de dados tenha sido menor em comparação com outros estudos, a alta acurácia indica que, mesmo com amostras mais limitadas, modelos bem ajustados podem oferecer resultados promissores para auxiliar profissionais da saúde em diagnósticos rápidos e confiáveis [8].

Avançando em direção a soluções integradas de telemedicina, autores propuseram um sistema completo para a detecção remota de *Trichuris trichiura*, utilizando smartphones com adaptadores 3D acoplados a microscópios convencionais. A inovação reside não apenas no uso

de IA para reconhecimento de ovos, mas na integração com uma plataforma de telemedicina que permite rotulagem remota e treinamento contínuo dos algoritmos. A precisão média de 98,44% aliada à sensibilidade de 80,94% sugere uma alternativa viável para triagens em campo, com boa concordância com a microscopia convencional [9].

Complementando essa abordagem integrada, ao utilizar sistema de aprendizado profundo em larga escala com imagens digitalizadas por um scanner portátil, aplicadas em amostras fecais de mais de 1.300 crianças no Quênia. O modelo apresentou alta sensibilidade e especificidade, sendo capaz de detectar infecções de baixa intensidade que passariam despercebidas pela análise microscópica humana. Isso reforça a eficácia da combinação entre escaneamento portátil, armazenamento em nuvem e análise algorítmica como ferramenta de apoio ao diagnóstico em regiões endêmicas [1].

De forma semelhante, Ward et al. [10] enfocaram uma solução escalável e de baixo custo, com aplicação em múltiplos países africanos e asiáticos. Seu sistema inclui um scanner de lâminas e um modelo IA para detecção e classificação automática de ovos de quatro espécies de helmintos, atingindo precisão e sensibilidade acima de 94%. A escala do estudo, com quase 17 mil ovos anotados em mais de 7 mil imagens, destaca o rigor metodológico e valida a viabilidade de implementação do sistema em larga escala para vigilância epidemiológica e diagnóstico parasitológico.

Esses estudos, ao empregarem diferentes dispositivos, algoritmos e estratégias de aquisição de imagem, demonstram convergência em três pontos principais: (i) a viabilidade de diagnósticos automatizados com alta precisão, mesmo em ambientes com infraestrutura limitada; (ii) a importância de soluções escaláveis e integradas com tecnologias móveis ou em nuvem; e (iii) o potencial impacto dessas ferramentas na detecção precoce e monitoramento de parasitoses em regiões endêmicas. A diversidade de abordagens, seja em tipos de parasitas, métodos diagnósticos ou tecnologias de hardware, contribui para o avanço de soluções personalizadas para distintos contextos epidemiológicos.

Embora, os estudos anteriores focassem em soluções práticas e protótipos para aplicação em campo, neste sentido, o foco de algumas pesquisas é na combinação de algoritmos de aprendizado profundo para detecção a partir de imagens fornecidas, neste contexto, autores utilizaram três arquiteturas de deep learning, ou Single Shot MultiBox Detector (SSD), U-Net e Faster R-CNN. Esta combinação permitiu a análise simultânea de amostras, oferecendo ao usuário a possibilidade de escolher a previsão mais precisa entre as opções fornecidas pelos modelos. Além de sua aplicação prática, a plataforma também funciona como uma ferramenta educacional valiosa para o treinamento em diagnóstico parasitológico. No entanto, embora eficiente, a abordagem depende de uma interface mais complexa para o usuário e de um maior volume de dados rotulados, que são armazenados no formato XML para treinamento do modelo. Isso pode limitar a acessibilidade em ambientes de baixo custo ou com recursos limitados de armazenamento [3].

A utilização de algoritmos de aprendizado profundo conhecidos como o estado da arte em visão computacional pode ser uma abordagem interessante, portanto, autores realizaram o pré-processamento das imagens, técnicas de aumento de dados e a aplicação do modelo You Only Look Once (YOLOv5) para detecção e classificação. O conjunto de dados, composto por 5.393 imagens de parasitas intestinais. O YOLOv5 alcançou uma precisão média de aproximadamente 97% e um tempo de detecção de apenas 8,5 ms por amostra. O estudo comparou o desempenho do YOLOv5 com outros modelos de detecção de objetos, como SSD, Faster R-CNN, AlexNet e ResNet50, demonstrando que o YOLOv5 superou os demais em termos de precisão média [2].

Em contextos em que os recursos computacionais são restritos, o modelo YAC-Net se destaca. Desenvolvido a partir do YOLOv5n, ele é otimizado para trabalhar com imagens de baixa resolução e borradas, algo comum em cenários práticos. A introdução de técnicas como a Rede Piramidal de Características Assintóticas (AFPN) e módulos C2f contribui para a redução da complexidade computacional, ao mesmo tempo em que melhora a precisão da detecção. Comparado ao YOLOv5n, o YAC-Net superou-o em diversas métricas, incluindo precisão, sensibilidade e F1-Score, enquanto reduziu em 20% o número de parâmetros. Isso demonstra a eficácia do YAC-Net em ambientes com limitações de recursos, tornando-o uma alternativa atraente para cenários com capacidade computacional reduzida [11].

Uma solução híbrida, que combina as capacidades das redes neurais convolucionais (CNNs) com a escalabilidade dos Transformadores de Visão (ViTs), também tem mostrado resultados promissores na classificação de ovos de parasitas. O CoAtNet, utilizando o conjunto de dados Chula-Parasite-Egg-11, superou modelos convencionais baseados em CNNs, como o

EfficientNet-B4 e DenseNet121, tanto em termos de precisão quanto de F1-Score. A principal vantagem do CoAtNet reside no seu equilíbrio entre a quantidade de parâmetros e o tempo de inferência, o que torna o modelo uma solução viável para tarefas de classificação com grandes volumes de dados. Embora o CoAtNet tenha mostrado bom desempenho, seu uso em contextos de recursos limitados ainda precisa ser mais explorado, já que modelos baseados em ViTs exigem maior poder computacional para treinamento e inferência [12].

Em comparação, todas essas abordagens apresentam forças e limitações dependendo dos requisitos específicos de cada contexto. Enquanto as plataformas como HEAP oferecem soluções educacionais e práticas, com forte dependência de recursos computacionais e grandes volumes de dados rotulados, o YOLOv5 e suas variações, como o YAC-Net, oferecem soluções mais ágeis e eficientes para contextos com limitações de hardware. Já o CoAtNet, com seu equilíbrio entre eficiência e precisão, parece ser a melhor escolha quando grandes volumes de dados precisam ser processados rapidamente, embora ainda careça de mais testes em ambientes com recursos limitados.

A integração da inteligência artificial com a microscopia eletrônica tem se mostrado uma promessa significativa para o diagnóstico automatizado de helmintíases transmitidas pelo solo e esquistossomose, com a capacidade de acelerar a triagem e direcionar tratamentos para áreas de maior necessidade, especialmente em contextos de recursos limitados, como em países de baixa e média renda. Essa combinação tecnológica permite uma análise mais eficiente e de alto rendimento, oferecendo um avanço considerável na saúde pública global. Contudo, questões relacionadas à privacidade dos dados e à harmonização das regulamentações internacionais precisam ser cuidadosamente abordadas para garantir a segurança e a proteção dos pacientes [13].

Por outro lado, a aplicação de tecnologias de microscopia de baixo custo, como o microscópio USB Vídeo Class (UVC) combinado com aplicativos de rede neural artificial, como o Kankanet, também apresenta vantagens em cenários de recursos limitados, como em comunidades rurais de Madagascar. O estudo piloto demonstrou que, apesar de o UVC não gerar imagens precisas para algumas espécies de helmintos devido à sua baixa resolução, o Kankanet foi eficaz na identificação de *A. lumbricoides* e ancilostomídeos, com uma sensibilidade notável. Embora a sensibilidade do Kankanet tenha sido inferior à de um parasitologista experiente, ele ainda se mostrou uma ferramenta promissora para ambientes com acesso restrito a microscópios de alta qualidade e especialistas treinados. Isso evidencia o potencial de tecnologias acessíveis para melhorar o diagnóstico e controle de helmintíases em regiões com recursos limitados, embora haja necessidade de melhorias na qualidade da imagem e no desempenho das redes neurais para espécies mais desafiadoras [14].

5 CONSIDERAÇÕES FINAIS

Esta revisão destaca o potencial transformador do Aprendizado de Máquina (ML) na área da saúde, especialmente no diagnóstico automatizado de parasitas de interesse médico. No entanto, ressalta-se que essa linha de pesquisa ainda está em desenvolvimento, demandando mais estudos para validar e aprimorar os modelos existentes, bem como para garantir a segurança e a ética em sua aplicação.

A implementação desses algoritmos requer infraestrutura tecnológica adequada, incluindo acesso à internet, dispositivos com capacidade de processamento e softwares específicos, pode representar um desafio em regiões remotas ou com infraestrutura limitada. Além disso, a qualidade das imagens microscópicas utilizadas no treinamento das redes neurais é um fator crítico, pois impacta diretamente a precisão e a eficiência do diagnóstico. A padronização dos métodos de coleta e processamento das amostras também é fundamental para assegurar a confiabilidade dos dados. Para um uso responsável do ML na saúde, é indispensável capacitar os profissionais da área para operar os dispositivos, interpretar os resultados e lidar com eventuais problemas técnicos.

Apesar das limitações desta revisão, como a possível insuficiência de dados para cobrir toda a literatura existente, o estudo reforça as oportunidades oferecidas pelos algoritmos de aprendizado profundo para a automação da detecção de parasitas em diferentes amostras biológicas. Essa abordagem tem o potencial de tornar o diagnóstico mais ágil, preciso e eficiente, favorecendo a identificação precoce de infecções, a instituição de tratamentos oportunos e a redução da transmissão de doenças, especialmente em áreas endêmicas e em países em desenvolvimento.

REFERÊNCIAS

1. N F, Jk A, Yn A, Sn F. Intestinal Parasitic Infection and Nutritional Status in Children under Five Years Old: A Systematic Review. *Tropical medicine and infectious disease* [Internet]. 2022 Nov 12;7(11). Disponível em: <https://pubmed.ncbi.nlm.nih.gov/36422922/>
2. Kumar S, Arif T, Ahamad G, Chaudhary AA, Khan S, Ali MAM. An Efficient and Effective Framework for Intestinal Parasite Egg Detection Using YOLOv5. *Diagnostics* [Internet]. 2023 Jan 1 [cited 2024 Mar 2];13(18):2978. Available from: <https://www.mdpi.com/2075-4418/13/18/2978>.
3. Lee CC, Huang PJ, Yeh YM, Li PH, Chiu CH, Cheng WH, et al. Helminth egg analysis platform (HEAP): An opened platform for microscopic helminth egg identification and quantification based on the integration of deep learning architectures. *Journal of Microbiology Immunology and Infection*. 2022 Jun 1;55(3):395–404.
4. Lundin J, Antti Suutala, Holmström O, Henriksson S, Severi Valkamo, Kaingu H, et al. Diagnosis of soil-transmitted helminth infections with digital mobile microscopy and artificial intelligence in a resource-limited setting. *PLoS neglected tropical diseases*. 2024 Apr 11;18(4):e0012041–1.
5. Tricco AC, Lillie E, Zarin W, O'Brien KK, Colquhoun H, Levac D, et al. PRISMA Extension for Scoping Reviews (PRISMA-ScR): checklist and explanation. *Ann Intern Med* [Internet]. 2018 [cited 2024 Jan 15];169(7):467–73. Available from: <http://dx.doi.org/10.7326/m18-0850>.
6. Oyibo P, Jujjavarapu S, Meulah B, Agbana T, Braakman I, van Diepen A, et al. Schistoscope: An Automated Microscope with Artificial Intelligence for Detection of *Schistosoma haematobium* Eggs in Resource-Limited Settings. *Micromachines* [Internet]. 2022 May 1;13(5):643. Available from: <https://www.mdpi.com/2072-666X/13/5/643>.
7. Maturana CR, Dantas A, Zarzuela F, Ruiz E, Sulleiro E, Mediavilla A, et al. Development of an automated artificial intelligence-based system for urogenital schistosomiasis diagnosis using digital image analysis techniques and a robotized microscope. *PLoS neglected tropical diseases*. 2024 Nov 5;18(11):e0012614–4.
8. Butploy N, Kanarkard W, Maleewong Intapan P. Deep Learning Approach for *Ascaris lumbricoides* Parasite Egg Classification. Magalhães LG, editor. *Journal of Parasitology Research*. 2021 Apr 26;2021:1–8.
9. Dacal E, Bermejo-Peláez D, Lin L, Álamo E, Cuadrado D, Martínez Á, et al. Mobile microscopy and telemedicine platform assisted by deep learning for the quantification of *Trichuris trichiura* infection. Steinmann P, editor. *PLOS Neglected Tropical Diseases*. 2021 Sep 7;15(9):e0009677.
10. Ward P, Dahlberg P, Lagatie O, Larsson J, Tynong A, Vlaminck J, et al. Affordable artificial intelligence-based digital pathology for neglected tropical diseases: A proof-of-concept for the detection of soil-transmitted helminths and *Schistosoma mansoni* eggs in Kato-Katz stool thick smears. Zhou XN, editor. *PLOS Neglected Tropical Diseases*. 2022 Jun 17;16(6):e0010500.
11. Xu W, Zhai Q, Liu J, Xu X, Hua J. A lightweight deep-learning model for parasite egg detection in microscopy images. *Parasites & Vectors*. 2024 Nov 6;17(1).
12. Nouar AlDahoul, Hezerul Abdul Karim, Mhd Adel Momo, Isabelle F, Vina Alyzza Magallanes, Joshua M. Parasitic egg recognition using convolution and attention network. *Scientific Reports*. 2023 Sep 2;13(1).
13. Mathison BA, Kohan JL, Walker JF, Smith RB, Ardon O, Couturier MR. Detection of Intestinal Protozoa in Trichrome-Stained Stool Specimens by Use of a Deep Convolutional Neural Network. Pritt BS, editor. *Journal of Clinical Microbiology*. 2020 Apr 15;58(6).
14. Yang A, Bakhtari N, Langdon-Embry L, Redwood E, Grandjean Lapierre S, Rakotomanga P, et al. Kankanet: An artificial neural network-based object detection smartphone application and mobile microscope as a point-of-care diagnostic aid for soil-transmitted helminthiasis. Bennuru S, editor. *PLOS Neglected Tropical Diseases*. 2019 Aug 5;13(8):e0007577.

Esta obra está licenciado com uma Licença [Creative Commons Atribuição-NãoComercial 4.0 Internacional](https://creativecommons.org/licenses/by-nc/4.0/).

