

Abordagens Atuais e Perspectivas Futuras para Diagnóstico de Malária Baseado em IA: Uma Revisão de Escopo do Estado da Arte

Current Approaches and Future Prospects for AI-Driven Malaria Diagnosis: A State-of-the-Art Scoping Review

Marcelo da Silva Lisboa¹, Silvanete Maria da Silva², Marcelo Lisboa Rocha³

RESUMO

Ultimamente, a inteligência artificial (IA), particularmente aprendizado de máquina e aprendizado profundo, tem se tornado cada vez mais proeminente na área da saúde, aprimorando decisões baseadas em dados e avançando o conceito One Health. Dentro do diagnóstico de malária, esses algoritmos de IA mostram grande potencial para resultados mais rápidos e precisos. Esta revisão de escopo examina os usos e aplicações do estado da arte mais recente de modelos de IA para detecção de malária, enfatizando sua capacidade de analisar imagens de esfregaços de sangue e outros fatores relevantes para auxiliar os profissionais de saúde no diagnóstico e contenção de doenças. Avaliamos minuciosamente o desempenho desses modelos e comparamos várias abordagens de ponta. Por fim, discutimos caminhos promissores de pesquisa futura para aprimorar o atendimento ao paciente e a infraestrutura de saúde.

Palavras-chave: Inteligência Artificial. Aprendizado de Máquina. Aprendizado Profundo. Malária. Revisão de Escopo. Estado da Arte.

ABSTRACT

Artificial intelligence (AI), particularly machine learning and deep learning, has become increasingly prominent in healthcare lately, improving data-driven decision-making and advancing the One Health concept. Within malaria diagnosis, these AI algorithms show great potential for faster and more accurate results. This scoping review examines the uses and applications of the latest state-of-the-art AI models for malaria detection, emphasizing their ability to analyze blood smear images and other relevant factors to assist healthcare professionals in diagnosing and containing the disease. We thoroughly evaluate the performance of these models and compare several state-of-the-art approaches. Finally, we discuss promising avenues for future research to improve patient care and healthcare infrastructure.

Keywords: Artificial Intelligence. Machine Learning. Deep Learning. Malaria. Scoping Review. State of the Art.

¹ Bach. em Ciência de Dados. Departamento de Tecnologia da Informação – Secretaria da Administração do Tocantins.

E-mail: marcelodasilvalisboa1@gmail.com

² Espec. em Letras. Secretaria da Educação do Estado do Tocantins.

E-mail: silvanetemaria20@gmail.com

³ DSc. em Eng. Elétrica. Programa de Pós-Graduação em Governança e Transformação Digital.

E-mail: mlisboa@uft.edu.br

ORCID: <https://orcid.org/0000-0002-4034-0021>

1. INTRODUÇÃO

A malária, uma crise de saúde global persistente, afeta mais de 200 milhões de pessoas a cada ano, concentradas principalmente em áreas tropicais e subtropicais onde os parasitas *Plasmodium* são transmitidos por mosquitos *Anopheles*. Esta doença continua sendo uma grande ameaça, ceifando milhões de vidas, especialmente entre crianças menores de cinco anos. A estrutura *One Health*^{A 1-2} traduzido para português como “Uma Só Saúde” ou “Saúde Única”, reconhece a interconexão da saúde humana, animal e ambiental, destacando que a malária não é apenas um problema de saúde humana. Influências ambientais como temperatura, umidade e água parada impactam a reprodução de mosquitos, enquanto fatores como expansão agrícola, desmatamento e migração humana facilitam a disseminação de doenças. Felizmente, o surgimento de técnicas sofisticadas de inteligência artificial, tal qual aprendizado profundo (em inglês *Deep Learning* - DL), oferece novas armas na luta contra a malária. O desenvolvimento de ferramentas que fazem uso de aprendizado profundo permite detecção rápida, previsão de surtos e estratégias de controle otimizadas. Este estudo investiga a sinergia entre a abordagem *One Health* e as técnicas de inteligência artificial, especificamente, o aprendizado profundo, no combate à malária. Aqui, é apresentada uma análise atualizada de técnicas e perspectivas de ponta, através do uso da inteligência artificial, para mitigar o impacto global desta doença devastadora.

Este artigo visa ampliar a perspectiva sobre o atual estado da arte em relação às abordagens atuais e perspectivas futuras para o diagnóstico de malária orientado por IA. Ao fazer isso, uma revisão de escopo abrangente é realizada para formular os atuais desafios de pesquisa endereçáveis.

2. MATERIAIS E MÉTODOS

Esta revisão de escopo seguiu uma abordagem por Peters, et al³ para informar o protocolo aplicado nesse trabalho.

Como fontes de dados para busca de trabalhos candidatos, escolhemos o seguinte: Scopus e ISI Web of Science (WoS). Ambas as fontes de dados juntas maximizam o número de trabalhos candidatos, pois indexam a maioria dos artigos existentes nas

^A O Ministério da Saúde do Brasil através do *One Health* visa transcender fronteiras disciplinares, setoriais e geográficas, buscando soluções sustentáveis e integradas para promover a saúde dos seres humanos e o meio ambiente mais amplo.

bibliotecas digitais mais importantes, como: ACM Digital Library, IEEEXplore e SpringerLink e muitas outras.

A *string* de busca utilizada foi “malária” AND (“artificial intelligence” OR “machine learn*” OR “deep learn*”) para uma análise aprofundada da relação entre os argumentos. O foco foi em trabalhos publicados a partir de 2023 para identificação do estado-da-arte, com prioridade para aqueles com mais citações ou um ponto de vista inovador.

Os resultados iniciais foram selecionados pelo título. Após a remoção das duplicatas, os critérios de inclusão e exclusão apresentados na Tabela 1 foram usados para reduzir os 28 artigos selecionados para 7. A Figura 1 mostra todo o processo de seleção de acordo com a diretrizes de revisão de escopo³.

Tabela 1. Critérios de inclusão e exclusão utilizados para triagem da literatura identificada.

Critério de Inclusão	Critério de Exclusão
Publicado a partir de 2023	Não é Artigo
Escrito em Inglês	Baixa Qualidade
Focado em IA para Malária	Não Focado em IA
Artigo de Alta Qualidade	Não em Inglês

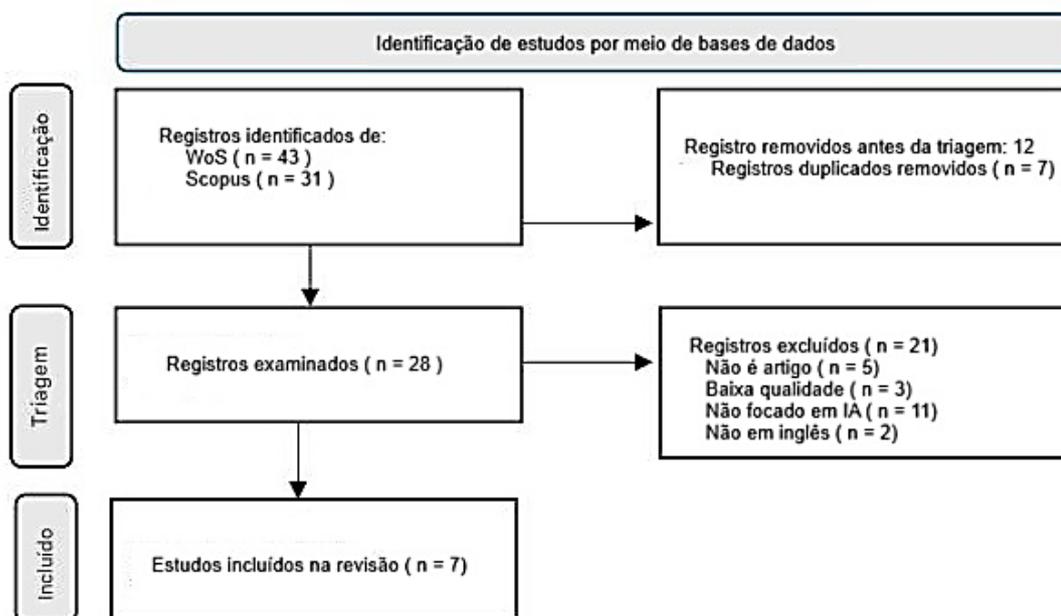


Figura 1. Fluxograma da busca para revisão de escopo.

Os artigos incluídos foram primeiramente revisados para identificar quaisquer novas aplicações de IA para identificação da malária. Finalmente, os artigos incluídos foram

combinados com aqueles usados para informar o mapa original e analisados, com a perspectiva de "o que está presente" e também de "quais são os seus potenciais" Ou quais são maiores necessidades de pesquisas futuras para aperfeiçoamento da aplicação de IA para identificação da malária. Os resultados dessas análises serão agora discutidos na seção de resultados.

3. RESULTADOS

Os trabalhos selecionados são divididos em subseções a seguir, de acordo com a abordagem usada.

3.1. Identificando a Malária com Aprendizado Profundo

Gill et al.⁴ tentam ajudar a abordagem tradicional que é trabalhosa e depende muito da experiência humana. Em particular, a microscopia tem sido o método padrão para diagnosticar a malária por um longo tempo, mas requer que amostras de sangue sejam examinadas sob um microscópio para identificar glóbulos vermelhos infectados pelos parasitas da malária. Esta pesquisa visa criar um modelo de classificação de imagem sustentável usando aprendizagem de transferência para aumentar a precisão e eficiência do diagnóstico da malária. O estudo foca especificamente no modelo de aprendizagem profunda VGG19. A rede pré-treinada mencionada antes demonstrou forte desempenho, alcançando uma taxa de precisão de mais de 90% na identificação da malária a partir de imagens de células e características indicativas de infecção por malária. Este avanço pode reduzir a dependência da microscopia manual e tornar os sistemas de detecção de malária mais eficientes e escaláveis.

Hemachadran et al.⁵ analisam o desempenho de vários algoritmos de aprendizagem profunda. Os modelos de rede neural considerados são Redes Neurais Convolucionais (CNN), como MobileNetV2 e ResNet50, avaliados usando um conjunto de dados de 27.558 imagens de esfregaços de sangue provenientes do *National Institutes of Health* (agência primária do governo dos Estados Unidos responsável pela pesquisa biomédica e de saúde pública). Este conjunto de dados inclui 13.780 imagens de células parasitadas sob um microscópio e 13.778 imagens de células não infectadas. Os resultados são promissores: MobileNetV2 surgiu como o de melhor desempenho, alcançando uma taxa de precisão (acerto) de 97,06%. Além da precisão, o estudo calculou métricas de desempenho

importantes, como perda de treinamento e teste, precisão, recall, pontuação F1 e curvas ROC.

Bhuiyan et al. ⁶ propõem uma solução inovadora: um modelo de conjunto. O modelo aproveita três redes de aprendizado profundo pré-treinadas que são VGG16, VGG19 e DenseNet201. Esses modelos são combinados usando uma abordagem de conjunto de média ponderada adaptativa para melhorar a precisão da previsão e aprimorados no momento da classificação por uma técnica de votação máxima para reduzir a variabilidade nos resultados. Uma característica notável do modelo é o uso da técnica de aumento de dados (processo de geração artificial de novos dados a partir de dados existentes) que ajuda a mitigar o *overfitting*^B e aumentar o tamanho do conjunto de dados. Os autores também comparam o desempenho de seu modelo com outras abordagens, como CNNs personalizadas, aprendizado de transferência e modelos híbridos CNN-Machine Learning. O modelo de conjunto proposto atingiu uma precisão de 97,92% na classificação de células parasitadas e não infectadas, superando os métodos alternativos testados.

3.2. Detecção de parasitas da malária via Aprendizado Profundo

Fasihfar et al. ⁷ focam na comparação de uma Rede Neural Densa (DNN) e uma Rede Neural Convolutacional (CNN) para avaliar sua capacidade de diagnosticar e classificar diferentes tipos de parasitas da malária usando imagens de esfregaços de sangue. A classificação dos parasitas da malária é particularmente importante porque diferentes espécies de parasitas (*Plasmodium Falciparum*, *Plasmodium Vivax* e *Plasmodium Ovale*) requerem estratégias de tratamento distintas. Este estudo considerou um conjunto de dados de 1.920 imagens de esfregaços de sangue divididos em amostras de 84 pacientes suspeitos de portar várias cepas de malária. Especificamente, o conjunto de dados incluiu 624 imagens de *Plasmodium Falciparum*, 548 de *Plasmodium Vivax*, 588 de *Plasmodium Ovale* e 160 imagens de indivíduos saudáveis. Um modelo exclusivo de segmentação de imagens foi desenvolvido para aumentar a precisão da análise. Este modelo eliminou eficientemente elementos irrelevantes das imagens de esfregaço de sangue permitindo que os algoritmos de aprendizado de máquina se concentrassem apenas em células

^B Ocorre quando um modelo se ajusta tão bem aos dados de treinamento que perde a capacidade de generalizar para novos dados. Como resultado, o modelo pode ter um desempenho excelente nos dados de treinamento, mas falhar ao fazer previsões precisas em dados não vistos.

terapeuticamente relevantes. O estudo revelou uma distinção clara no desempenho dos dois modelos: enquanto a rede neural tradicional alcançou uma precisão média de 95,11% classificando os parasitas, a CNN a superou com uma precisão de 99,59%. Essa diferença destaca a capacidade superior das CNNs de lidar com tarefas complexas de classificação de imagens, especialmente em ambientes médicos.

A identificação precisa do tipo de parasita é essencial para um gerenciamento eficaz do paciente. A classificação incorreta da cepa correta da malária pode levar a tratamentos inadequados que podem prolongar a doença ou aumentar o risco de complicações.

3.3. Detecção de Parasitas da Malária por Meio da Detecção de Objetos

Avanços recentes em métodos de aprendizado profundo fizeram melhorias significativas nesta área, mas os desafios permanecem. Em particular, quando se trata de detectar pequenos objetos como parasitas da malária em imagens microscópicas de película de sangue, os modelos no estado da arte atuais para detecção de objetos têm um pouco de dificuldade. Além disso, esses modelos baseados em rede neural tipicamente perdem detalhes espaciais devido à redução de escala.

O estudo de Shewajo et al. ⁸ propõe uma abordagem inovadora usando detecção de objetos para aprimorar a detecção de parasitas da malária. A estrutura de detecção de objetos considera imagens de esfregaços de sangue de alta resolução de um novo ponto de vista. O modelo pode dividir imagens de alta resolução em blocos menores aplicando um método de processamento de imagem baseado em blocos. Em particular, três variantes de detectores de objetos baseados em YOLOv4 (*You Only Look Once*) foram empregadas e treinadas em 1.780 imagens microscópicas de esfregaço espesso de alta resolução infectadas com *Plasmodium Falciparum* com blocos gerados a partir dessas imagens para otimizar o desempenho. Os resultados demonstraram uma melhoria significativa tanto na precisão da detecção quanto na capacidade de generalização, com o modelo de melhor desempenho alcançando um *recall*^c de 95,3%. Simultaneamente, o modelo usando detecção de objetos atingiu 87,1% de precisão média, superando significativamente as abordagens anteriores. Essas descobertas sugerem que o método baseado em blocos combinado com detecção de objetos faz uma melhoria em tarefas como pequenos objetos

^c O *recall* mede a capacidade do modelo de identificar corretamente todos os exemplos positivos em um conjunto de dados. É especialmente importante em situações onde é crucial minimizar os falsos negativos.

que são tipicamente sub-representados em conjuntos de dados de referência. Essa abordagem mantém a velocidade de detecção em tempo real, tornando-a prática e eficaz para fins clínicos.

Esta abordagem melhora a eficiência e a precisão da detecção de parasitas sem a necessidade de reduzir a resolução das imagens de entrada, preservando informações espaciais cruciais que geralmente são perdidas em modelos tradicionais.

Liu et al.⁹ desenvolveram o AIDMAN, um sistema de diagnóstico de malária baseado em inteligência artificial que recebe imagens de entrada capturadas de uma câmera de smartphone. Os usuários tiram fotos de esfregaços finos de sangue no microscópio, que são então processados por meio de um pipeline de diagnóstico. O sistema integra o modelo YOLOv5 e a arquitetura *Transformer*^D para analisar essas imagens de smartphone. O YOLOv5 detecta células individuais no esfregaço de sangue e um Attentional Aligner Model (AAM) aplica recursos multiescala e mecanismos de atenção para classificar as células. Finalmente, uma Rede Neural Convolutiva (CNN) é usada para confirmar o diagnóstico, reduzindo a interferência de falsos positivos. O AIDMAN atinge um desempenho diagnóstico excepcional: precisão de 98,62% para células individuais e 97% para imagens completas de esfregaços de sangue. Se você comparar os resultados, a validação clínica mostra uma precisão de 98,44%. O uso de imagens de smartphones torna este sistema pronto para uso e acessível em áreas onde equipamentos de laboratório e parasitologistas especialistas são escassos.

3.4. Previsão de Surtos de Malária via Aprendizado Profundo

Singh et al.¹⁰ propõem um novo algoritmo híbrido de aprendizado de máquina chamado P2CA-PSO-ANN para prever surtos de malária em três distritos do Rajastão, Índia Ocidental. Os autores consideram várias variáveis meteorológicas, como umidade relativa, temperatura e precipitação como características de entrada para seu modelo preditivo e as combinam por meio de fusão de dados linear. Os autores aplicam a Análise de Componentes Principais Probabilísticas (P2CA) para extrair informações não correlacionadas dos dados de entrada e aumentar a robustez do modelo. O conjunto de dados refinado é então usado para treinar uma Rede Neural Artificial com hiperparâmetros

^D É um modelo de aprendizado profundo que utiliza mecanismos de atenção para processar dados.

otimizados usando a Otimização de Enxame de Partículas (PSO), que é um algoritmo de otimização bioinspirado. O modelo é treinado em dados meteorológicos mensais de 2009 a 2012, atingindo um coeficiente de correlação de 0,99 e um Erro Quadrático Médio (RMSE) de 1,76. O desempenho deste modelo híbrido também é comparado a vários algoritmos de aprendizado de máquina estabelecidos, incluindo Generalised Regression Neural Network (GRNN), Gaussian Process Regression (GPR), Support Vector Regression (SVR), Random Forest e Radial Basis Neural Networks (RBNN). A comparação mostra que o modelo P2CA-PSO-ANN supera essas técnicas em termos de precisão.

Esta abordagem representa uma ferramenta significativa para sistemas de alerta precoce que visam antecipar e mitigar surtos de malária em regiões vulneráveis.

4. DISCUSSÃO

As ferramentas de IA estão melhorando continuamente e visam transformar o diagnóstico, tratamento e prevenção da malária. Como mencionado anteriormente, um exemplo dessa inovação é o uso do YOLO^E para a detecção rápida de células infectadas. O YOLO pode detectar não apenas células infectadas, mas também células saudáveis com sua capacidade de identificar e localizar células em tempo real. Uma vez que as células são localizadas, elas são colocadas em caixas delimitadoras para serem extraídas como "instâncias" individuais para análise posterior. Neste ponto, nossos trabalhos anteriores em outros domínios entram em jogo.

Abordagens de Aprendizado de Instâncias Múltiplas (MIL) como utilizada em Vocaturo et al.¹¹ podem vir após as identificações e segmentações YOLO das células para declarar se a imagem inteira da amostra de sangue é positiva ou negativa para malária. Depois disso, a eficácia do sistema YOLO e MIL pode ser aprimorado pela integração de outras tecnologias, como fluorescência ou o pré-processamento de segmentação usado no trabalho de Rani et al.¹². Além disso, esses sistemas podem ser usados como ferramentas de confirmação de diagnóstico por meio de tecnologias como Grad-CAM para verificar diagnósticos antes do tratamento. Um aspecto crucial da adoção em larga escala dessas tecnologias é a descentralização do processo de diagnóstico. Neste ponto, o método de Aprendizado Federado já aplicado no trabalho de Caroprese et al.¹³ entra em cena,

^E YOLO é um modelo de aprendizado profundo para detecção de objetos em tempo real. Ele é amplamente utilizado em visão computacional devido à sua capacidade de detectar objetos em imagens e vídeos com alta velocidade e precisão.

permitindo que os modelos aprendam com dados distribuídos em várias clínicas sem transferir informações confidenciais. Por último, mas não menos importante, os mesmos princípios poderiam ser aplicados a doenças zoonóticas, que são infecções transmitidas de animais para humanos. O monitoramento da presença de parasitas em amostras de sangue animal poderia facilitar o controle e a prevenção de zoonoses, reduzindo o risco de surtos em animais e humanos, ajudando a tornar a *One Health* uma realidade mais palpável em relação à malária e até outras doenças como febre amarela. Pesquisa e colaboração contínuas são cruciais para tornar essas inovações acessíveis a todos e melhorar o controle da malária para salvar vidas.

5. CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS

Este trabalho revisou as aplicações atuais e perspectivas futuras da Inteligência Artificial (IA), especificamente aprendizado de máquina e aprendizado profundo, no diagnóstico e controle da malária, alinhado ao conceito One Health. A pesquisa demonstrou o potencial da IA para aprimorar a precisão e a velocidade do diagnóstico, automatizando a análise de imagens de esfregaços sanguíneos e integrando dados epidemiológicos e ambientais. Foram identificadas abordagens promissoras como o uso de redes neurais convolucionais (CNNs), modelos de conjunto, detecção de objetos e aprendizado federado. Essas técnicas demonstram capacidade de superar a microscopia manual em termos de eficiência e, em alguns casos, precisão, além de possibilitar a previsão de surtos.

Apesar dos avanços, lacunas persistem. A generalização dos modelos para diferentes cepas de *Plasmodium* e condições de imagem ainda é um desafio. A disponibilidade de conjuntos de dados robustos e diversificados, representativos de diferentes cenários epidemiológicos, é crucial para o treinamento de modelos mais eficazes. A integração da IA em dispositivos móveis para diagnóstico em locais remotos com recursos limitados também requer mais investigação, considerando a variabilidade na qualidade das imagens e a necessidade de soluções de baixo custo. A interpretabilidade dos modelos de IA permitindo a compreensão das decisões tomadas pelos algoritmos, é outro aspecto importante para a confiança e adoção clínica. Finalmente, a avaliação do impacto real dessas tecnologias em programas de saúde pública, considerando fatores como custo-efetividade e aceitação pelos profissionais de saúde, é fundamental para sua implementação em larga escala.

Como possíveis trabalhos futuros temos:

- Desenvolvimento de modelos de IA robustos à variação de cepas de Plasmodium, artefatos de imagem e qualidade de esfregaços sanguíneos.
- Criação de conjuntos de dados públicos e diversificados de imagens de malária para treinamento e validação de modelos.
- Investigação de técnicas de aprendizado federado para treinar modelos de IA em dados distribuídos, preservando a privacidade do paciente.
- Desenvolvimento de sistemas de IA para dispositivos móveis de baixo custo, visando o diagnóstico da malária em áreas remotas.
- Avaliação do impacto da IA em programas de saúde pública, considerando custo-efetividade e aceitação pelos profissionais.
- Exploração da integração de dados ambientais e epidemiológicos em modelos de IA para previsão de surtos e direcionamento de intervenções.
- Pesquisa sobre métodos para melhorar a interpretabilidade dos modelos de IA facilitando a compreensão de suas decisões.

A IA tem o potencial de revolucionar o diagnóstico e o controle da malária, contribuindo para a eliminação dessa doença. A continuidade da pesquisa e o desenvolvimento de soluções inovadoras são essenciais para alcançar esse objetivo.

REFERÊNCIAS

1. Destoumieux-Garzón D, Mavingui P, Boetsch G, Boissier J, Darriet F, Duboz P, et al. The one health concept: 10 years old and a long road ahead. *Frontiers in veterinary science*. 2018; 5: 14.
2. Brasil MdSd. Uma Só Saúde. [Online].; 2024 [cited 2025 jan 20. Available from: <https://www.gov.br/saude/pt-br/assuntos/saude-de-a-a-z/u/uma-so-saude>.
3. Peters MD, Marnie C, Tricco AC, Pollock D, Munn Z, Alexander LaMP, et al. Updated methodological guidance for the conduct of scoping reviews. *JBHI evidence synthesis*. 2020: p. 2119--2126.
4. Gill KS, Anand V, Gupta R. An Efficient VGG19 Framework for Malaria Detection in Blood Cell Images. In *2023 3rd Asian Conference on Innovation in Technology (ASIANCON)*; 2023. p. 1–4.
5. Hemachandran K, Alasiry A, Marzougui M, Ganie SM, Pise AA, Alouane MTH, et al. Performance analysis of deep learning algorithms in diagnosis of malaria disease. *Diagnostics*. 2023; 13: 534.
6. Bhuiyan M, Islam MS. A new ensemble learning approach to detect malaria from microscopic red blood cell images. *Sensors International*. 2023; 4: 100209.

7. Fasihfar Z, Rokhsati H, Sadeghsalehi H, Ghaderzadeh M, Gheisari M. AI-driven malaria diagnosis: developing a robust model for accurate detection and classification of malaria parasites. *Iranian Journal of Blood and Cancer*. 2023; 15: 112–124.
8. Shewajo FA, Fante KA. Tile-based microscopic image processing for malaria screening using a deep learning approach. *BMC Medical Imaging*. 2023; 23: 39.
9. Liu R, Liu T, Dan T, Yang S, Li Y, Luo B, et al. AIDMAN: An AI-based object detection system for malaria diagnosis from smartphone thin-blood-smear images. *Patterns*. 2023; 4.
10. Singh A, Mehra M, Kumar A, Niranjannaik M, Priya D, Gaurav K. Leveraging hybrid machine learning and data fusion for accurate mapping of malaria cases using meteorological variables in western India. *Intelligent Systems with Applications*. 2023; 17: 200164.
11. Vocaturo E, Zumpano E, Giallombardo G, Miglionico G. DC-SMIL: a multiple instance learning solution via spherical separation for automated detection of displastic nevi. In *Proceedings of the 24th symposium on international database engineering & applications*; 2020. p. 1–9.
12. Rani G, Thakkar P, Verma A, Mehta V, Chavan R, Dhaka VS, et al. KUB-UNet: segmentation of organs of urinary system from a KUB X-ray image. *Computer Methods and Programs in Biomedicine*. 2022; 224: 107031.
13. Caroprese L, Ruga T, Vocaturo E, Zumpano E. Revealing brain tumor with federated learning. In *2023 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*; 2023. p. 3868–3873.