

Health Guardian - A inteligência artificial a serviço do tratamento das doenças tropicais negligenciadas

Hilson G. Vilar de Andrade^{1,2}, Maicon Herverton Lino Ferreira da Silva Barros¹,
Maria Eduarda Ferro de Mello¹, Patricia Takako Endo¹

¹Universidade de Pernambuco (UPE)
Pernambuco – Brasil

²Instituto Federal de Educação, Ciência e Tecnologia de Pernambuco (IFPE)
Pernambuco – Brasil

{hgva2, mhlfsb, mefm}@ecomp.poli.br, patricia.endo@upe.br

Abstract. *Diseases such as malaria, arboviruses, tuberculosis, and leprosy, known as neglected tropical diseases, pose a threat to the health of low-income populations, negatively impacting the quality of life of affected individuals. This article introduces the Health Guardian, a collaborative application that uses artificial intelligence to assist healthcare professionals in the decision-making process regarding the treatment of neglected tropical diseases, aiming to improve the efficiency of care and the quality of life of patients.*

Resumo. *Doenças como a malária, as arboviroses, a tuberculose e a hanseníase, conhecidas como doenças tropicais negligenciadas, são uma ameaça à saúde das populações de baixa renda, impactando negativamente na qualidade de vida dos indivíduos afetados. Este artigo apresenta o Health Guardian, um aplicativo colaborativo que utiliza inteligência artificial para auxiliar profissionais de saúde no processo de tomada de decisão quanto ao tratamento de doenças tropicais negligenciadas, visando melhorar a eficiência do atendimento e a qualidade de vida dos pacientes.*

1. Contexto

Doenças tropicais negligenciadas, como malária, arboviroses (como dengue, Chikungunya e zika), tuberculose e hanseníase, representam ameaças na saúde das populações de baixa renda em regiões tropicais e subtropicais, impactando negativamente na qualidade de vida dos indivíduos afetados. Essas doenças são assim denominadas porque muitas vezes afetam os mais vulneráveis, perpetuando um ciclo de pobreza e desigualdade [Hotez 2021]. Embora haja tratamentos disponíveis, o acesso a esses recursos é frequentemente escasso. Além disso, a falta de investimentos para pesquisas e inovações direcionadas a essas doenças resulta em diagnósticos imprecisos e opções terapêuticas limitadas.

A equidade no Sistema Único de Saúde (SUS) é um princípio fundamental que busca garantir que os cidadãos brasileiros tenham acesso igualitário a serviços de saúde de qualidade, independentemente de sua origem étnica, socioeconômica, geográfica ou outras características. Neste cenário, a inteligência artificial, juntamente com a análise de dados, pode desempenhar um papel crucial na promoção da equidade no SUS no

tratamento de doenças negligenciadas. Por exemplo, através da análise de dados, a inteligência artificial pode identificar áreas com maiores carências de assistência médica e populações vulneráveis, permitindo uma melhor alocação de recursos e a implementação de estratégias e políticas públicas direcionadas para atender às necessidades específicas de diferentes grupos. A capacidade de aprender com dados em tempo real e adaptar-se a novas informações permite uma resposta ágil aos surtos de doenças ou mudanças nas necessidades da população [de Castañeda et al. 2019, Zafar et al. 2022, Barboza et al. 2023].

2. Problema

Muitas soluções baseadas em inteligência artificial para saúde são caras e inacessíveis para regiões com recursos limitados, pois exigem exames laboratoriais e até mesmo de imagem [Goyal et al. 2020, Sharma et al. 2021] para auxiliar no processo de aprendizagem dos modelos.

A proposta denominada Health Guardian, destaca a importância de melhorar o tratamento especificamente dessas doenças negligenciadas, utilizando inteligência artificial, como uma solução de baixo custo, para auxiliar no diagnóstico clínico mais preciso, bem como na triagem de casos com maior probabilidade de desfecho negativo. Um outro diferencial do Health Guardian é a colaboração dos usuários (profissionais de saúde) para auxiliar no processo de melhoria do aprendizado dos modelos de inteligência artificial.

3. Objetivos

O Health Guardian é um aplicativo colaborativo baseado em inteligência artificial para auxiliar no tratamento de doenças tropicais negligenciadas, um grupo de enfermidades que historicamente têm recebido menos atenção e recursos do que outras condições de saúde globalmente.

O objetivo maior é fortalecer a missão do SUS de fornecer cuidados de saúde de qualidade para os brasileiros, independentemente de sua situação socioeconômica. Isso pode representar um passo significativo em direção à redução das disparidades de saúde e à melhoria da qualidade de vida das populações afetadas por doenças tropicais negligenciadas.

4. Estágio da pesquisa

Atualmente, o Health Guardian está em fase de prototipação, com os seguintes pontos de foco:

4.1. Suporte aos profissionais de saúde

Através de modelos de inteligência artificial que combina dados históricos clínicos e sociodemográficos, o Health Guardian fornece um suporte a tomada de decisão aos profissionais de saúde para a triagem de casos com maior probabilidade de um desfecho negativo.

Atualmente, o Health Guardian conta com a integração de três modelos de inteligência artificial já existentes: TITO¹ (para predição de óbito por tuberculose) [Lino Ferreira da Silva Barros et al. 2021, Da Silva et al. 2023], VALERIA² (para classificação clínica de arbovirose) [Tabosa de Oliveira et al. 2022,

¹<https://tito.deeptub.app/>

²<http://valeria.upecaruaru.com.br/index.html>

Da Silva Neto et al. 2023] e hansen.ai (para classificação de deficiências resultantes da doença).

A Figura 1 apresenta a tela do protótipo do aplicativo Health Guardian, do ponto de vista do usuário profissional de saúde. É possível escolher qual doença o profissional gostaria de auxílio para tomada de decisão, e de acordo com os dados de saúde do paciente, prever o risco de um desfecho negativo.

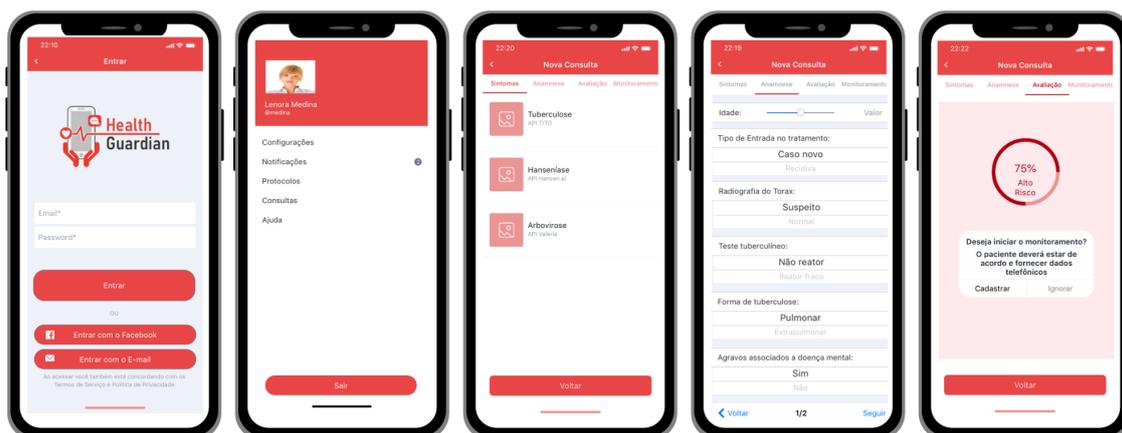


Figura 1. Telas do protótipo do aplicativo Health Guardian - Uso do profissional de saúde.

4.2. Acompanhamento dos pacientes

Através de mensagens de alerta para os pacientes mais vulneráveis (Figura 2), mediante a autorização no ato da consulta médica, o Health Guardian pode enviar lembretes sobre o horário correto das medicações, agendamento dos exames, data das consultas e outras etapas do tratamento definidas pelo médico responsável.

Além disso, o paciente também é estimulado a seguir corretamente o protocolo do tratamento clínico através da bonificação com GCoins (uma moeda virtual gerenciada pelo Health Guardian), que podem ser trocadas por produtos e serviços de empresas parceiras, formando assim um ecossistema completo e colaborativo, centrado no uso do aplicativo.

4.3. Aprimoramento contínuo com colaboração dos usuários

O Health Guardian envolve ativamente os profissionais de saúde, permitindo-lhes contribuir para melhorar e ajustar constantemente os modelos de inteligência artificial. Para isso, os resultados reais dos casos tratados com base nas recomendações dos modelos são avaliados (Figure 3) e os profissionais de saúde podem identificar lacunas ou discrepâncias entre as previsões dos modelos e os resultados reais. Isso pode incluir casos em que os modelos falharam em prever um desfecho negativo ou onde houve falsos positivos.

Os modelos são re-treinados iterativamente com base nos dados atualizados e melhorias sugeridas pelos profissionais de saúde. Esse processo de treinamento contínuo pode ser realizado através do uso de *pipelines* de *Machine Learning Operations* (MLOps),



Figura 2. Tela do protótipo do aplicativo Health Guardian - Uso do paciente.

que automatizam o processo de re-treinamento dos modelos sempre que novos dados estão disponíveis.

Essa abordagem de colaboração entre profissionais de saúde e especialistas em inteligência artificial permite um aprimoramento constante dos modelos, tornando-os mais eficazes e relevantes para a prática clínica real. Além disso, essa colaboração contribui para o desenvolvimento de modelos mais robustos e confiáveis, com base na experiência clínica dos próprios usuários do Health Guardian.

5. Potencial de contribuição

A participação ativa dos profissionais de saúde na revisão e aprimoramento dos modelos gera um ciclo de retroalimentação valioso para a manutenção do Health Guardian. Isso leva à expansão da base de dados e conhecimento com base em experiências clínicas reais, vivenciada no dia-a-dia dos profissionais, usuários do Health Guardian, e como consequência maior, impacta positivamente na qualidade de vida dos pacientes.

A abordagem colaborativa do Health Guardian pode inspirar pesquisas adicionais em aprendizado contínuo e LLM. Por exemplo, *large language models* (LLMs) podem ser utilizados para personalizar recomendações de tratamento com base nas interações anteriores dos profissionais de saúde com a plataforma e os resultados observados. Essas recomendações do LLM podem/devem ser validadas (avaliar riscos e benefícios) pelos profissionais de saúde com base na compreensão das necessidades dos pacientes atendidos, podendo considerar fatores pessoais, histórico médico e outras informações relevantes ao fazer recomendações específicas.

Adicionalmente, os dados agregados podem ser usados para pesquisas futuras e estudos epidemiológicos e modelos LLM podem analisar continuamente os dados clínicos e identificar tendências emergentes e padrões de diagnóstico e de tratamento. Importante ressaltar que quando um LLM sugere novos protocolos de tratamento com base em



Figura 3. Envio de avaliação da predição do Health Guardian pelo profissional de saúde.

tendências emergentes, os profissionais de saúde desempenham um papel fundamental na validação e implementação desses protocolos.

Agradecimentos

Este trabalho foi financiado pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), Fundação de Amparo à Ciência e Tecnologia do Estado de Pernambuco (FACEPE) e Universidade de Pernambuco (UPE), uma entidade do Governo do Estado de Pernambuco focada na promoção do ensino, pesquisa e extensão. Patricia Takako Endo é financiada pelo CNPq, como bolsa de produtividade.

Referências

- [Barboza et al. 2023] Barboza, M. F. X., de Carvalho Monteiro, K. H., Dourado, R. A., Sampaio, V. S., and Endo, P. T. (2023). Enhancing malaria prediction in amazonas, brazil: A comparative analysis of deep learning models based on clustering.
- [Da Silva et al. 2023] Da Silva, M. H. L. F., Sampaio, V. D. S., Endo, P. T., et al. (2023). Machine-learning model for classification of the prognosis of tuberculosis using real data from brazil. In *2023 18th Iberian Conference on Information Systems and Technologies (CISTI)*, pages 1–6. IEEE.
- [Da Silva Neto et al. 2023] Da Silva Neto, S. R., Tabosa, T., Medeiros Neto, L., Teixeira, I. V., Sadok, S., De Souza Sampaio, V., and Endo, P. T. (2023). Binary models for arboviruses classification using machine learning: A benchmarking evaluation.
- [de Castañeda et al. 2019] de Castañeda, R. R., Durso, A. M., Ray, N., Fernández, J. L., Williams, D. J., Alcoba, G., Chappuis, F., Salathé, M., and Bolon, I. (2019). Sna-

kebite and snake identification: empowering neglected communities and health-care providers with ai. *The Lancet Digital Health*, 1(5):e202–e203.

- [Goyal et al. 2020] Goyal, M., Knackstedt, T., Yan, S., and Hassanpour, S. (2020). Artificial intelligence-based image classification methods for diagnosis of skin cancer: Challenges and opportunities. *Computers in biology and medicine*, 127:104065.
- [Hotez 2021] Hotez, P. J. (2021). *Forgotten people, forgotten diseases: the neglected tropical diseases and their impact on global health and development*. John Wiley & Sons.
- [Lino Ferreira da Silva Barros et al. 2021] Lino Ferreira da Silva Barros, M. H., Oliveira Alves, G., Morais Florêncio Souza, L., da Silva Rocha, E., Lorenzato de Oliveira, J. F., Lynn, T., Sampaio, V., and Endo, P. T. (2021). Benchmarking machine learning models to assist in the prognosis of tuberculosis. In *Informatics*, volume 8, page 27. MDPI.
- [Sharma et al. 2021] Sharma, A. K., Nandal, A., Dhaka, A., and Dixit, R. (2021). Medical image classification techniques and analysis using deep learning networks: a review. *Health informatics: a computational perspective in healthcare*, pages 233–258.
- [Tabosa de Oliveira et al. 2022] Tabosa de Oliveira, T., da Silva Neto, S. R., Teixeira, I. V., Aguiar de Oliveira, S. B., de Almeida Rodrigues, M. G., Sampaio, V. S., and Endo, P. T. (2022). A comparative study of machine learning techniques for multi-class classification of arboviral diseases. *Frontiers in Tropical Diseases*, 2:769968.
- [Zafar et al. 2022] Zafar, A., Attia, Z., Tesfaye, M., Walelign, S., Wordofa, M., Abera, D., Desta, K., Tsegaye, A., Ay, A., and Taye, B. (2022). Machine learning-based risk factor analysis and prevalence prediction of intestinal parasitic infections using epidemiological survey data. *PLOS Neglected Tropical Diseases*, 16(6):e0010517.