

# Otimização para sistema de apoio à decisão clínica: uma proposta embarcada com SLM e XAI

Gabriel de Queiroz Sousa; Instituto de Computação - Universidade Federal do Amazonas; [gabriel.queiroz@icomp.ufam.edu.br](mailto:gabriel.queiroz@icomp.ufam.edu.br);  
Fabiola Guerra Nakamura; Instituto de Computação – Universidade Federal do Amazonas

## 1. Introdução

Os Sistemas de Apoio à Decisão Clínica (SADC) são ferramentas bem estabelecidas que assistem profissionais de saúde em seus complexos fluxos de trabalho<sup>1</sup>. Estes sistemas promovem o uso eficiente de recursos, elevam a confiança nos diagnósticos e melhoram o prognóstico do paciente. No entanto, a literatura aponta que a implementação e adoção desses sistemas enfrentam barreiras significativas. Entre as dificuldades mais comuns, destacam-se a baixa confiança dos profissionais de saúde, a complexidade de interpretação de resultados, problemas de usabilidade, a precariedade da infraestrutura de TI e os custos elevados. A resistência de parte da classe médica e a falta de integração com os fluxos de trabalho existentes também são fatores que limitam o uso eficaz dessas ferramentas<sup>1,2</sup>.

Diante dessas dificuldades, este trabalho propõe uma arquitetura de SADC que utiliza um conjunto de tecnologias projetadas para superar as barreiras identificadas. A solução abrange um pipeline com as seguintes etapas:

1. A coleta de dados históricos e relatos de pacientes, utilizando um *Small Language Model* (SLM) para extrair os sintomas de maneira eficiente<sup>3,4</sup>;
2. A padronização e o enriquecimento desses dados por meio de uma ontologia médica, que os prepara para a análise do modelo<sup>3</sup>;
3. A utilização de um modelo clássico de aprendizado de máquina, como o Random Forest, para sugerir a especialidade médica mais adequada para o encaminhamento do paciente<sup>5,6</sup>;
4. A aplicação de IA Explicável (XAI) para justificar a recomendação, aumentando a transparência e a confiança dos usuários<sup>4,5,6</sup>;
5. Execução de todo o processo de forma local em um sistema embarcado de baixo custo, como o Raspberry Pi, resolvendo os problemas de infraestrutura e privacidade<sup>2</sup>.

## 2. Material e Métodos

O objetivo principal desta pesquisa é propor e validar uma Prova de Conceito (PoC) de um SADC que demonstre a viabilidade de uma solução de baixo custo, segura e transparente, projetada para lidar com as principais barreiras de implementação identificadas na literatura<sup>2</sup>. Para atingir este objetivo, a pesquisa se desdobra em uma sequência de metas específicas, como demonstrar a viabilidade de um SLM embarcado<sup>3,4</sup>, validar o pipeline de análise e recomendação<sup>3,4</sup>, prover justificativa e transparência<sup>5,6</sup>, e enfrentar as barreiras de implementação<sup>2</sup>. A abordagem da PoC se concentra numa arquitetura de baixo custo e alta transparência.

## 2.1. Arquitetura e Componentes do Sistema

O pipeline do SADC será construído sobre uma arquitetura de software embarcado, utilizando o Raspberry Pi 5 de 16GB como plataforma. O hardware escolhido, com seu custo acessível, demonstra viabilidade de uma solução local e descentralizada. A arquitetura do sistema é composta pelos seguintes componentes:

- **Coleta e Processamento de Dados:** A coleta de sintomas a partir dos relatos dos pacientes será realizada por um SLM, como o TinyLlama, com inferência baseada em prompt. Essa abordagem, em vez de um LLM mais robusto, é uma escolha estratégica para garantir o desempenho em hardware limitado, priorizando a eficiência para a PoC<sup>3,4</sup>.
- **Modelo de Classificação:** O modelo escolhido foi o Random Forest devido à sua robustez e por ser altamente compatível com técnicas de XAI, permitindo uma análise clara de suas decisões<sup>5,6</sup>.
- **Ontologia Médica:** Será empregada a Classificação Internacional de Atenção Primária (CIAP-2). Essa ontologia foi especificamente projetada para o contexto de APS, classificando dados não apenas por diagnósticos, mas por razões de encontro e sintomas<sup>5</sup>.
- **IA Explicável:** Para justificar a recomendação do modelo e promover a confiança do profissional de saúde, será utilizada a técnica SHAP (SHapley Additive exPlanations). O SHAP, por sua natureza agnóstica a modelos, fornece uma explicação quantitativa da contribuição de cada sintoma e dado histórico para a decisão final do Random Forest<sup>5,6</sup>.

## 2.2. Etapas da Prova de Conceito

O projeto será executado em uma série de etapas sequenciais para validar o pipeline proposto:

1. **Construção do Conjunto de Dados:** Um conjunto de dados sintético será criado com aproximadamente 5 instâncias. Este conjunto simulará o formato do e-Layout SUS APS, contendo relatos de pacientes e dados históricos, o que servirá como base para os experimentos.
2. **Análise de Sintomas e Mapeamento Ontológico:** Os relatos de pacientes serão submetidos ao SLM, que extrairá os sintomas e os mapeará para os códigos correspondentes da ontologia CIAP-2.
3. **Classificação e Recomendação:** O modelo Random Forest receberá os dados padronizados e fará a classificação, gerando uma sugestão de especialidade médica para o encaminhamento do paciente.
4. **Geração de Justificativa:** A técnica SHAP será aplicada para analisar a decisão do modelo, gerando uma justificativa clara e visual da razão pela qual a especialidade foi recomendada.

## 3. Resultados e Discussão

Os SADC possuem diversas dificuldades durante seu processo, desde a concepção até a implantação, dentre eles, estão os altos custos relacionados a esse tipo de sistema, problemas de infraestrutura e segurança da informação<sup>2</sup>. Dessa forma, este trabalho propõe e valida uma PoC para um SADC de baixo custo, seguro e transparente. Por se tratar de um estudo

metodológico, os resultados esperados demonstram a viabilidade da abordagem proposta, e a discussão foca em como essa solução pode mitigar as principais barreiras de implementação identificadas na literatura.

A principal contribuição da pesquisa é a demonstração de que um pipeline de processamento de dados para SADC pode ser executado de forma eficaz em um sistema embarcado de baixo custo. O uso de uma plataforma como o Raspberry Pi 5 resolve as questões de infraestrutura e custos elevados que impedem a adoção dessas ferramentas, especialmente em ambientes de APS com recursos limitados. A solução embarcada também aborda a privacidade dos dados, uma vez que todo o processo ocorre localmente, sem a necessidade de conexão com a nuvem ou servidores externos.

O pipeline de processamento, que utiliza um SLM, como o TinyLlama, para extrair sintomas de relatos de pacientes<sup>3,4</sup> e a ontologia médica CIAP-2 para padronização<sup>5</sup>, demonstra uma alternativa viável e eficiente a modelos de linguagem maiores e mais caros (LLM). A combinação do modelo de aprendizado de máquina Random Forest e a técnica SHAP<sup>5,6</sup>, garante que as recomendações sejam precisas e transparentes. A geração de uma justificativa clara e visual para a decisão do modelo promove a confiança dos profissionais de saúde, superando uma das principais barreiras apontadas na literatura.

Ainda que o conjunto de dados utilizado seja sintético e de pequena escala, a validação da PoC é suficiente para confirmar a viabilidade técnica da arquitetura. O projeto representa um passo significativo em direção a uma solução prática e acessível para o encaminhamento de pacientes na APS, superando as barreiras de implementação de forma integrada e inovadora.

#### **4. Conclusões**

A presente pesquisa abordou as complexas barreiras de implementação de SADC na APS, como os altos custos, a infraestrutura de TI precária e a baixa confiança dos profissionais de saúde nos sistemas de IA<sup>2</sup>. Diante disso, foi proposta uma arquitetura de SADC que integra tecnologias de ponta de forma estratégica e viável.

O principal mérito deste trabalho reside em sua contribuição metodológica: a demonstração de que é possível construir um pipeline de processamento de dados robusto em uma plataforma de baixo custo, local e transparente. A PoC confirma a viabilidade de uma solução que supera as barreiras de implementação, tornando a IA acessível para ambientes com recursos limitados.

Olhando para o futuro, a arquitetura modular da solução permite diversas expansões. Trabalhos futuros podem incluir a adaptação do pipeline para lidar com dados clínicos reais, a integração de outras fontes de dados e o desenvolvimento de um mecanismo híbrido de atualização de modelos. Em última análise, este projeto representa um passo significativo em direção a uma solução prática e acessível para o encaminhamento de pacientes na APS, pavimentando o caminho para uma aplicação mais ampla da IA em ambientes clínicos.

**Palavras-Chave:** SADC, APS, SLM, XAI, sistemas embarcados

#### **Agradecimentos (Item Não obrigatório)**

Gostaria de agradecer à minha orientadora pelas oportunidades providas, que foram fundamentais para o meu desenvolvimento como pesquisador, e pelo compartilhamento de

conhecimento nesse curto período juntos. Também gostaria de agradecer aos professores de pós-graduação pelos ensinamentos, que tornaram possível o desenvolvimento dessa pesquisa e que muito agregaram à minha compreensão da área, ao laboratório de bioinformática dos professores Nakamura e ao programa de pós-graduação por permitir o acesso a oportunidades como essa e outras.

## 5. Referências

1. Rajashekar NC, Shin YE, Pu Y, Chung S, You K, Giuffre M, et al. Human-Algorithmic Interaction Using a Large Language Model-Augmented Artificial Intelligence Clinical Decision Support System. Em: Proceedings of the CHI Conference on Human Factors in Computing Systems [Internet]. Honolulu HI USA: ACM; 2024 [citado 25 de agosto de 2025]. p. 1–20. Disponível em: <https://dl.acm.org/doi/10.1145/3613904.3642024>
2. Derksen C, Walter FM, Akbar AB, Parmar AVE, Saunders TS, Round T, et al. The implementation challenge of computerised clinical decision support systems for the detection of disease in primary care: systematic review and recommendations. *Implementation Sci.* 17 de julho de 2025;20(1):33.
3. Yang H, Shen Z, Shao J, Men L, Han X, Dong J. LLM-Augmented Symptom Analysis for Cardiovascular Disease Risk Prediction: A Clinical NLP. arXiv preprint arXiv:250711052 [Internet]. 2025 [citado 25 de agosto de 2025]; Disponível em: <https://arxiv.org/abs/2507.11052>
4. Salehin I, Sajib MTA, Badhon NH, Rifat MSH, Amin N, Moon NN. Systematic Literature Review of LLM-Large Language Model in Medical: Digital Health, Technology and Applications. 2025 [citado 25 de agosto de 2025]; Disponível em: <https://www.authorea.com/doi/full/10.22541/au.174587258.81848862>
5. Kim SY, Kim DH, Kim MJ, Ko HJ, Jeong OR. XAI-based clinical decision support systems: a systematic review. *Applied Sciences.* 2024;14(15):6638.
6. Talukder N. Clinical decision support system: an explainable AI approach [Internet] [Master's Thesis]. N. Talukder; 2024 [citado 25 de agosto de 2025]. Disponível em: <https://oulurepo.oulu.fi/handle/10024/49375>