

Anamnese Intuitiva Orientada por IA

Rian Beskow Friedrich

Curso de Ciência da Computação

Universidade Franciscana

CEP 97010-032 – Santa Maria, RS, Brasil

rian.friedrich@ufn.edu.br

Sylvio André Garcia Vieira

Curso de Ciência da Computação

Universidade Franciscana

CEP 97010-032 – Santa Maria, RS, Brasil

sylvio@ufn.edu.br

Resumo—Este trabalho apresenta o desenvolvimento de uma ferramenta Web para a Anamnese Intuitiva Orientada por Inteligência Artificial (IA), com foco na otimização do pré-diagnóstico de doenças cardíacas. A aplicação web integra a coleta eficiente de informações do paciente para analisar dados com base em um extenso dataset e em um modelo de aprendizado de máquina. Com este trabalho, é fornecido um pré-diagnóstico percentual confiável ao profissional de saúde, buscando níveis elevados de eficiência e precisão. A metodologia do projeto e desenvolvimento priorizou a usabilidade e uma experiência satisfatória, que também contribui com segurança, privacidade e ética dos dados do usuário para aplicações futuras. Os resultados e as implicações do protótipo são discutidos, juntamente com possíveis aplicações futuras, ressaltando o potencial dessa ferramenta para transformar a interação médica.

Palavras-chave—Inteligência Artificial, Aprendizado de Máquina, Doenças Cardíacas, Anamnese.

I. INTRODUÇÃO

Segundo Porto e Costa [1], a anamnese é a primeira e uma das mais importantes etapas do tratamento clínico. Ela consiste em uma conversa guiada entre o profissional de saúde e o paciente, visando compreender sua história de saúde e o motivo da consulta. É similar a uma entrevista, na qual são feitas perguntas sobre sintomas, doenças pregressas, histórico familiar e hábitos. A anamnese também pode ser realizada virtualmente, por meio de questionários online, videochamadas, aplicativos e outras ferramentas digitais. Essa modalidade oferece vantagens como maior comodidade e acessibilidade, otimização do tempo da consulta, potencial melhora na qualidade e precisão das informações coletadas e redução de custos, entre outros benefícios.

A anamnese tem como função fundamental auxiliar no diagnóstico dos problemas de saúde. Contudo, o diagnóstico nem sempre é um processo direto, pois existem desafios significativos tanto na anamnese quanto na fase diagnóstica em si, como a sobreposição de sintomas de diferentes doenças. Muitas condições compartilham manifestações semelhantes, como fadiga, dor, febre ou inflamação, o que pode dificultar a identificação precisa da patologia. Por exemplo, a fadiga pode ser um sintoma de inúmeras condições, desde um simples resfriado até doenças autoimunes complexas. Adicionalmente, algumas doenças podem se apresentar de formas atípicas, com sintomas que não se encaixam no quadro clínico esperado, tornando o diagnóstico correto ainda mais desafiador.

O tratamento clínico, dada a sua complexidade e a natureza da resposta biológica do organismo, é um processo que demanda tempo. Não se devem esperar resultados imediatos, mas sim uma evolução gradual. Essa característica é inerente à forma como o corpo reage às intervenções terapêuticas, e o acompanhamento profissional contínuo é crucial durante todo esse período para monitorar o progresso e ajustar o tratamento conforme necessário.

A crescente implementação da tecnologia na área da saúde é uma realidade, oferecendo novas ferramentas e abordagens, especialmente diante do grande número de pessoas com problemas de saúde agudos ou crônicos. Nesse cenário, a Inteligência Artificial (IA) surge como um avanço transformador que pode auxiliar significativamente na interpretação da anamnese. A IA consegue identificar padrões e correlações nas informações do paciente, sugerir diagnósticos diferenciais ao apresentar uma lista de possibilidades, detectar inconsistências ou lacunas nos dados coletados, prever riscos e complicações ao analisar o histórico, e otimizar o tempo do profissional de saúde, liberando-o para focar na interação direta com o paciente. Em resumo, a IA atua como um poderoso suporte, aprimorando a capacidade de análise e contribuindo para uma assistência médica mais eficiente e personalizada.

Com base no artigo de Felipe Floresti [2], as doenças cardiovasculares (DCVs) representam a principal causa de morte no Brasil e no mundo, superando até mesmo os óbitos por COVID-19 em 2022, com aproximadamente 400 mil vidas perdidas apenas no território brasileiro. Entre as condições mais letais, destacam-se o infarto do miocárdio e o acidente vascular cerebral (AVC), responsáveis por 76% das mortes relacionadas a DCVs na América Latina Tropical. Apesar dos avanços nas últimas décadas, que reduziram as taxas de mortalidade ajustadas por idade em 55,6% no Brasil, esses problemas persistem como um desafio crítico para a saúde pública, especialmente em regiões com menor acesso a serviços de saúde e políticas de prevenção.

Identificar essas doenças de forma antecipada e o controle de fatores de risco como hipertensão, diabetes, colesterol elevado, tabagismo e sedentarismo são fundamentais para reduzir o impacto dessas doenças. Nesse contexto, ferramentas, como a IA, surgem como aliadas estratégicas. Ao correlacionar dados do paciente com bases clínicas validadas (ex.: *dataset Heart Disease*), o sistema pode agilizar a suspeição de DCVs e oferecer pré-diagnósticos percentuais, otimizando o tempo

do profissional.

A. Objetivo Geral

O objetivo deste trabalho é desenvolver uma ferramenta web para anamnese de fácil compreensão que, utilizando técnicas de mineração de dados, auxilie na identificação de um provável diagnóstico.

B. Objetivos específicos

A partir do objetivo geral, pode-se destacar os seguintes objetivos específicos:

- Testar algoritmos de aprendizado de máquina para identificar qual melhor se adapta aos dados utilizados;
- Aplicar o algoritmo de aprendizado de máquina selecionado para treinar o modelo;
- Facilitar o preenchimento da anamnese de forma padronizada;
- Aplicar o modelo treinado nos dados da anamnese;
- Predizer possíveis diagnósticos de acordo com a correlação dos dados de entrada com a base treinada;

II. REFERENCIAL TEÓRICO

Nesta seção, serão abordados os conceitos necessários para compreensão do trabalho, bem como termos utilizados nos trabalhos correlacionados, da Seção 3.

A. Anamnese

Segundo Yehia et al. [3], Anamnese é uma consulta realizada pelo médico ou outro profissional da saúde para coletar informações essenciais sobre o paciente, incluindo: Sintomas atuais, histórico médico pessoal e familiar, hábitos de vida (alimentação, sono, atividade física) e uso de medicamentos e alergias.

B. Inteligência Artificial - IA

Segundo Russel et al. [4], Inteligência Artificial é a simulação de inteligência humana por máquinas, permitindo que computadores aprendam com dados, reconheçam padrões e tomem decisões. Usada em assistentes virtuais, recomendações online e assim como neste trabalho, em diagnósticos médicos, a IA evolui com técnicas como *machine learning* (*Tópico explicado na próxima subseção*) para automatizar tarefas e melhorar eficiência em diversos setores.

C. Machine learning (Aprendizado de Máquina)

Segundo Bishop [5], *Machine Learning* é um ramo da Inteligência Artificial que permite aos sistemas aprenderem com dados sem serem explicitamente programados. Por meio de algoritmos, os computadores identificam padrões, fazem previsões e melhoram seu desempenho com a experiência.

D. LLM - Large Language Model

Segundo Mitchell [6], LLM é um tipo de inteligência artificial treinado para entender, gerar e processar linguagem humana de forma avançada.

E. RAG - Retrieval-Augmented Generation

Segundo Lewis et al. [7], RAG é uma técnica de IA que combina busca em bases de dados externas com geração de texto por modelos de linguagem (LLMs). Primeiro, o sistema recupera informações relevantes e busca semântica. Em seguida, o LLM gera respostas precisas e contextualizadas com base nesses dados, reduzindo erros e distorção de informações.

F. Framework PICOS

Segundo Methley et al. [8], O framework PICOS é uma estrutura utilizada principalmente na área de pesquisa científica, especialmente em revisões sistemáticas e meta-análises, para definir critérios claros e organizados para a seleção e avaliação de estudos. O acrônimo PICOS representa: Population (População): Grupo ou população-alvo do estudo (ex.: pacientes com doenças cardiovasculares), Intervention (Intervenção): Tratamento, técnica ou tecnologia avaliada (ex.: uso de um novo algoritmo, medicamento), Comparison (Comparação): Grupo de controle ou alternativa comparativa (ex.: placebo, método tradicional), Outcomes (Resultados): Métricas ou efeitos medidos (ex.: taxa de sobrevivência, acurácia do modelo) e Study Design (Desenho do Estudo): Metodologia utilizada (ex.: ensaio clínico randomizado, estudo de coorte).

G. Django e Python

Segundo Matthes [9], Python é uma linguagem de programação de alto nível, conhecida por sua sintaxe clara e legível, o que a torna ideal para iniciantes e profissionais. Criada por Guido van Rossum em 1991, ela é *interpretada*, *multiparadigma* (suporta programação procedural, orientada a objetos e funcional) e *multiplataforma*.

Django é um framework web de alto nível escrito em Python, projetado para facilitar o desenvolvimento rápido, seguro e escalável de aplicações web. Ele segue o padrão MVT (*Model-View-Template*), que separa em *Model* (dados), *View* (interface) e *Controller* (lógica), ele é uma variação do conhecido MVC (*Model-View-Controller*) que troca o *Controller* pela *View* (que vira lógica) e usa *Template* (HTML) no lugar da *View*, e inclui diversas funcionalidades prontas para uso.

H. Bibliotecas em Python

• LangChain

Segundo a documentação oficial [10], LangChain é um framework de código aberto projetado para facilitar o desenvolvimento de aplicações baseadas em modelos de linguagem (LLMs). Ele permite conectar LLMs a fontes externas de dados, APIs, bancos de dados e outras ferramentas, criando fluxos de trabalho automatizados.

• Ollama

Segundo a documentação oficial [11], Ollama é uma ferramenta que permite executar modelos de linguagem grandes (LLMs) localmente em sua máquina, sem depender de APIs externas.

• Whisper

Segundo a documentação oficial [12], Whisper é um modelo de reconhecimento de voz *offline*. Converte coman-

dos de fala em texto para o LLM processar, viabilizando interação por voz sem internet.

- **Transformers (Hugging Face)**

Segundo a documentação oficial [13], Transformers (Hugging Face) é uma biblioteca central para carregar modelos como Whisper e LLaMA. Fornece pipelines prontos para processamento de voz e texto.

- **Sentence Transformers**

Segundo a documentação oficial [14], Sentence Transformers são modelos de IA especializados em gerar embeddings, eles transformam frases, palavras ou documentos em vetores densos, permitindo comparar similaridade entre textos de forma eficiente.

I. Scrum e Kanban

Segundo Schwaber e Sutherland [15], Scrum é um framework ágil para gerenciamento de projetos, amplamente utilizado no desenvolvimento de software e em outras áreas que demandam flexibilidade e adaptação a mudanças. Ele se baseia em princípios de colaboração, transparência, inspeção e adaptação, permitindo que equipes entreguem valor de forma incremental e iterativa.

Segundo Anderson [16], Kanban é um método ágil de gestão de trabalho visual que ajuda a otimizar fluxos, reduzir desperdícios e melhorar a eficiência em processos contínuos. Diferente do Scrum (que trabalha com iterações fixas como Sprints), o Kanban é flexível e baseado em demanda, focando na entrega incremental e no limite de trabalho em progresso (WIP).

J. Pipeline

Segundo VanderPlas [17], Pipeline é um fluxo automatizado de processamento de dados, onde cada etapa executa uma tarefa específica e passa o resultado para a próxima. Em IA, um pipeline pode incluir coleta de dados, pré-processamento, treinamento do modelo e geração de respostas.

K. Ferramentas, APIs e Serviços Externos

- **OpenStreetMap** Segundo a documentação oficial [18], OpenStreetMap é um serviço de mapas colaborativo e de código aberto, utilizado para criação e distribuição de dados geográficos gratuitos. Funciona como alternativa ao Google Maps, permitindo edições comunitárias e integração em projetos que necessitam de dados geoespaciais personalizados.

- **Google Maps** Segundo a documentação oficial [19], Google Maps é uma plataforma de mapeamento global desenvolvida pelo Google, oferecendo navegação, visualização de ruas (*Street View*) e APIs para integração em aplicações. É amplamente usado em sistemas que requerem geolocalização precisa, rotas e dados de negócios.

- **Llama 3.1 (8B)** Segundo a documentação oficial [20], Llama 3.1 (8B) é um modelo de linguagem de inteligência artificial desenvolvido pela Meta (Facebook). Ele faz parte da família Llama 3, que inclui versões de diferentes tamanhos, sendo o 8B uma das variantes mais leves e eficientes.

L. Chatbots na Saúde

Com base nos relatórios sobre saúde digital da OMS [21], e Denecke et al. [22], Chatbots são sistemas de IA que simulam conversas humanas para coletar dados, responder perguntas ou auxiliar em tarefas específicas. Na saúde, são usados para anamnese automatizada, triagem de pacientes e suporte a diagnósticos. Suas vantagens incluem agilidade, padronização de informações e redução de custos, mas desafios como limitações em casos complexos e falta de empatia exigem combinação com avaliação médica tradicional.

M. Privacidade e Segurança em Dados Médicos

Com base na lei Geral de Proteção de Dados (LGPD) - Lei nº 13.709/2018O [23], a lei de segurança do HIPAA [24], e a norma de segurança de dados ISO/IEC 27001:2022 [25], o manuseio de dados de saúde requer compliance com leis como a LGPD (Brasil) e HIPAA (EUA), que exigem consentimento do paciente, anonimização e criptografia. O sistema proposto deve garantir: armazenamento seguro, acesso restrito a profissionais autorizados e transparência sobre o uso dos dados, evitando vazamentos ou violações.

N. Bases de Dados e o Algoritmo para Diagnóstico

A base de dados que inicialmente alimenta o sistema chama-se *Heart Disease* [26] e está disponível no repositório de dados Kaggle, no endereço <https://www.kaggle.com/datasets/oktayrdeki/heart-disease>. Esta base de dados é voltada à saúde do coração, e possui 10000 registros de pacientes com 21 atributos como idade, pressão sanguínea, sexo, hábitos saudáveis e de ingestão de fumo e álcool, bem como a presença de portadores de doenças cardíacas na família. No final traz o atributo classe de existência ou não de doença cardíaca, como pode ser visto na Tabela I. O Algoritmo *Decision Tree Classifier* correlaciona dados a diagnósticos, usando métricas de precisão (ex.: acurácia, recall) para minimizar falsos positivos/negativos.

Atributo	Descrição	Tipo
Age	Idade	Numérico
Gender	Gênero	Categórico
Blood Pressure	Pressão sanguínea	Numérico
Cholesterol Level	Colesterol	Numérico
Exercise Habits	Exercício (Alto/Baixo)	Categórico
Smoking	Fumante (Sim/Não)	Categórico
Family Heart Disease	Histórico familiar	Categórico
Diabetes	Diabetes (Sim/Não)	Categórico
BMI	IMC	Numérico
High Blood Pressure	Hipertensão (Sim/Não)	Categórico
Low HDL Cholesterol	LDL baixo	Categórico
High LDL Cholesterol	LDL alto	Categórico
Alcohol Consumption	Álcool (Alto/Médio/Baixo/Nenhum)	Categórico
Stress Level	Estresse (Alto/Médio/Baixo)	Categórico
Sleep Hours	Horas de sono	Numérico
Sugar Consumption	Açúcar (Alto/Médio/Baixo)	Categórico
Triglyceride Level	Triglicerídeos	Numérico
Fasting Blood Sugar	Glicemia em jejum	Numérico
CRP Level	Proteína C-Reativa	Numérico
Homocysteine Level	Homocisteína	Numérico
Heart Disease Status	Doença cardíaca (Sim/Não)	Categórico

Tabela I: Descrição dos Atributos para Análise de Doença Cardíaca

O. Validação e Ética em Sistemas de IA Médica

A validação envolverá comparação com diagnósticos reais e testes com médicos e pacientes. Ética e crítica: o sistema deve sinalizar incertezas, evitar substituir o julgamento humano e incluir revisão periódica para mitigar vieses (ex.: sub-representação de grupos populacionais).

III. TRABALHOS CORRELATOS

A. Software de predição de alterações de estabilidade da atenção pré-natal

O trabalho de Backes et al. [27] apresenta um software inovador destinado a identificar e predizer alterações na estabilidade da atenção pré-natal. Essa ferramenta emprega dados de saúde e geoprocessamento para monitorar surtos e epidemias, como sífilis congênita e dengue, em estágios iniciais, fornecendo informações preditivas cruciais para gestores de saúde. O objetivo principal é capacitar decisões estratégicas rápidas, padronizar dados e integrar inovações na saúde materno-infantil, alinhando-se à Agenda 2030 da ONU e às metas do Ministério da Saúde brasileiro.

A metodologia envolveu a coleta de dados do sistema de saúde da Prefeitura de Santa Maria/RS. Um desafio significativo foi a inconsistência nos nomes dos bairros, que foi corrigida manualmente com base na Lei Complementar nº 42/2006 de Santa Maria e validada via OpenStreetMap e Google Maps. Os dados padronizados são armazenados em um banco de dados relacional. Para geoprocessamento e visualização, os dados são integrados a um arquivo geográfico e apresentados por meio de mapas temáticos, gráficos de barras e linhas gerados com Matplotlib (Python), com filtros por CID e período.

Os resultados demonstram a eficácia da correção de dados, transformando uma base inconsistente em uma fonte confiável para análises. A visualização de dados por meio de mapas e gráficos permitiu a identificação de áreas críticas e tendências temporais, impactando diretamente a gestão da saúde com maior agilidade na detecção de surtos. A ferramenta é acessível a profissionais de saúde sem necessidade de conhecimento em TI, comprovando sua viabilidade para vigilância em saúde. Sugere-se futuras melhorias, como o uso de bibliotecas interativas e a automação da correção de dados com *machine learning*.

O estudo de Backes et al. [27] é fundamental para o presente trabalho, pois serve como uma referência metodológica e conceitual para o desenvolvimento de sistemas de IA em saúde. Ele oferece percepções valiosas sobre a concepção e validação de software, a metodologia de tratamento de dados inconsistentes (como a padronização de informações geográficas), e a integração de tecnologias para análise e visualização de dados. As soluções e os desafios abordados neste estudo, especialmente no manuseio de dados do sistema de saúde e sua transformação em informações confiáveis, são diretamente aplicáveis e fornecem subsídios importantes para a construção da Anamnese Intuitiva Orientada por IA.

B. Módulo LLM Local em Sistema Web para Geração de Relatórios Textuais via Prompt

O trabalho de TCC de Luiz Cardoso [28] teve como objetivo principal desenvolver um módulo de interação textual em linguagem natural para um sistema web (Python-Django). Esse módulo permitia que usuários gerassem relatórios automatizados por meio de prompts em português, visando aprimorar a interação humano-computador nos sistemas de informação do Laboratório de Práticas da Computação da Universidade Franciscana (UFN).

A metodologia empregada incluiu uma pesquisa aprofundada em IA generativa, LLMs, Transformers e RAG, bem como ferramentas como LangChain e Ollama. A implementação técnica utilizou o modelo Llama 3.1 hospedado localmente via Ollama, integrado ao sistema web existente SISGEP-COMIC (um sistema de gerenciamento de pesquisas hospitalares) por meio de RPC (do Inglês, *Remote Procedure Call*, é uma forma de um programa chamar uma função em outro computador como se fosse local). Uma aplicação de RAG (*Retrieval-Augmented Generation*) foi crucial para contextualizar as consultas com base no esquema do banco de dados, armazenado em JSON. A avaliação do trabalho foi realizada através de testes comparativos entre consultas SQL manuais e as geradas pelo módulo, analisando métricas como tempo de execução, precisão dos dados, consistência das respostas e taxa de falhas.

Entre os resultados, destacam-se um protótipo funcional integrado ao SISGEP-COMIC, capaz de gerar relatórios a partir de prompts em linguagem natural e convertê-los em SQL. O trabalho também produziu diagramas de arquitetura do sistema e protótipos de interface, como a tela de prompt para administradores. Embora dados concretos não tenham sido detalhados, a metodologia de avaliação com fórmulas para precisão, consistência e taxa de falhas foi descrita. Desafios significativos incluíram limitações de hardware e a complexidade na interpretação de linguagem natural para a geração de consultas SQL complexas.

O trabalho de Luiz Cardoso é de extrema importância para o presente trabalho. Ele serve como um precedente técnico e metodológico fundamental, demonstrando a viabilidade de utilizar LLMs e RAG para processar linguagem natural e gerar informações estruturadas em um ambiente web. A experiência de Cardoso na integração de sistemas, contextualização de dados e avaliação de desempenho oferece diretrizes práticas e descobertas valiosas para o desenvolvimento do protótipo do presente trabalho, ajudando a otimizar a precisão do pré-diagnóstico e a superar desafios comuns em projetos com IA generativa.

C. Transforming Health Care Through Chatbots for Medical History-Taking and Future Directions: Comprehensive Systematic Review

O estudo de Hindelang et al. [29] realizou uma revisão sistemática para avaliar o papel, eficácia, usabilidade e aceitação de chatbots na coleta de históricos médicos (anamnese), inves-

tigando também desafios e oportunidades para sua integração clínica.

A metodologia envolveu buscas em bases de dados médicas (PubMed, Embase, etc.) até julho de 2024, utilizando o framework PICOS para seleção de estudos em inglês sobre chatbots para anamnese, excluindo verificadores de sintomas isolados. A qualidade dos estudos (observacionais e ensaios clínicos randomizados) foi avaliada.

Os principais resultados, baseados em 18 estudos (2015-2023), indicaram que chatbots foram aplicados em diversas áreas médicas, trazendo benefícios como melhoria na completude dos dados, maior engajamento do paciente e redução no tempo de coleta de históricos. A aceitação pelos pacientes foi positiva, especialmente para históricos familiares. Contudo, foram identificadas limitações, incluindo a qualidade variável dos estudos analisados, a preferência dos pacientes por médicos em discussões sensíveis devido à falta de empatia dos chatbots, e desafios no manejo de diagnósticos complexos. O estudo também destacou um aumento exponencial nas publicações sobre chatbots na medicina desde 2017.

O trabalho de Hindelang et al. é de alta relevância para o presente trabalho, pois ele oferece uma visão geral valiosa sobre o uso de chatbots para anamnese, fornecendo um alerta sobre os desafios a serem considerados ao aplicar IA na anamnese, servindo como uma referência importante para contextualizar, justificar e aprimorar o presente trabalho.

D. Conversational AI with large language models to increase the uptake of clinical guidance

O trabalho de Marcia et al. [30] explora a integração de Modelos de Linguagem de Grande Escala (LLMs) em sistemas de saúde, como o Retrieval-Augmented Generation (RAG), para aprimorar o acesso de profissionais de saúde a diretrizes clínicas. O trabalho visa desenvolver e discutir o valor de um sistema baseado em IA que solucione os problemas dos LLMs atuais, como a geração de informações falsas ou engonosas.

A metodologia envolve o design e o debate sobre um sistema impulsionado por IA que utiliza LLMs e aplicações conversacionais, como o ChatGPT, para reavaliar como os profissionais de saúde acessam as diretrizes clínicas. A integração de LLMs em sistemas como o RAG é proposta como uma solução para os desafios de LLMs, como a geração de informações imprecisas.

Os resultados deste trabalho destacam o potencial transformador dos sistemas de IA conversacionais, baseados em LLMs, na disseminação e acesso às diretrizes clínicas. Foi observado que a integração de LLMs com mecanismos como o Retrieval-Augmented Generation (RAG) é crucial para mitigar a geração de informações falsas ou engonosas, um problema comum em LLMs puros. Dessa forma, o estudo projeta um cenário onde a adoção de orientações clínicas pode ser significativamente aumentada, oferecendo aos profissionais de saúde uma ferramenta mais eficiente e confiável para a consulta de informações.

O trabalho de Marcia et al. é vital para o presente trabalho. Ele valida o uso de LLMs na saúde e, crucialmente, demonstra

como a integração com RAG pode garantir a precisão das informações, evitando informações falsas ou engonosas. Isso é fundamental para que o pré-diagnóstico e referências científicas sejam confiáveis. Além disso, a ênfase na eficiência do acesso à informação reforça o objetivo de otimizar o tempo do médico, fornecendo dados precisos e referenciados de forma ágil, e as discussões sobre desafios éticos e de segurança orientam o desenvolvimento responsável do protótipo do presente trabalho.

IV. METODOLOGIA

A primeira etapa para o desenvolvimento deste trabalho foi o levantamento dos requisitos que permitiram projetar adequadamente as tarefas a serem desenvolvidas. Assim foram definidos os requisitos funcionais e não funcionais do sistema.

A. Requisitos Funcionais (RF)

Os requisitos funcionais descrevem as funcionalidades que o sistema deve oferecer aos usuários.

- RF 1: Coleta de Dados do Paciente:** O sistema deve permitir a coleta de informações gerais do paciente, como nome, idade, peso, hábitos (tabagismo, consumo de álcool), presença de diabetes e histórico familiar de doenças cardíacas.
- RF 2: Armazenamento de Dados:** O sistema deve armazenar as informações submetidas pelo paciente em um conjunto de dados (*dataset*).
- RF 3: Análise de Dados pelo Algoritmo:** O sistema deve utilizar o algoritmo selecionado para analisar os dados do paciente em conjunto com o *dataset* existente.
- RF 4: Predição de Diagnóstico:** O sistema deve fornecer uma estimativa percentual da probabilidade de o paciente apresentar uma condição cardíaca.
- RF 5: Apresentação de Pré-Diagnóstico ao Médico:** O sistema deve apresentar ao médico um indicativo de pré-diagnóstico de doença cardíaca associada, com base na análise do algoritmo.
- RF 6: Padronização da Anamnese:** O sistema deve facilitar o preenchimento da anamnese de forma padronizada.

B. Requisitos Não Funcionais (RNF)

Os requisitos não funcionais especificam critérios de qualidade e restrições sobre como o sistema deve se comportar.

- RNF 1: Usabilidade:** O sistema deve ser de fácil compreensão e utilização para o paciente e o profissional de saúde.
- RNF 2: Tecnologia:** O sistema deve ser desenvolvido utilizando HTML, CSS, Bootstrap e Python Django.
- RNF 3: Arquitetura:** O sistema deve ser uma aplicação web e incluir uma predição de probabilidade de doença cardíaca utilizando inteligência artificial.
- RNF 4: Escalabilidade:** O sistema deve ser capaz de gerenciar e integrar novos dados de pacientes, em conjunto com um dataset existente de mais de 10 mil registros.
- RNF 5: Segurança e Privacidade (LGPD/HIPAA):** O sistema deve estar em conformidade com leis de proteção

de dados, como a LGPD (Brasil) e HIPAA (EUA), exigindo consentimento do paciente, anonimização e criptografia dos dados.

- **RNF 6: Confiabilidade e Precisão:** O sistema deve utilizar o algoritmo selecionado e a base de dados validada de maneira eficiente para correlacionar os dados a diagnósticos, minimizando falsos positivos e negativos.
- **RNF 7: Ética:** O sistema deve evitar substituir o julgamento humano, a fim de ser apenas uma ferramenta adicional.
- **RNF 8: Manutenibilidade:** O sistema deve ser passível de validação através da comparação com diagnósticos reais e testes com médicos e pacientes.

C. Desenvolvimento

Este trabalho foi desenvolvido por meio das ferramentas HTML, CSS, Bootstrap e Python/Django. Considerando os desafios inerentes ao tratamento clínico e ao processo de anamnese. A plataforma disponibiliza uma anamnese prática, onde o paciente pode fornecer suas informações gerais, como nome, idade, peso, bem como detalhes sobre seus hábitos (tabagismo, consumo de álcool) e histórico de saúde (presença de diabetes, histórico familiar de doenças cardíacas). Após o paciente submeter esses dados clicando em 'Enviar Anamnese', as informações são armazenadas de forma segura em um banco de dados, que é enriquecido e comparado com mais de 10 mil registros de outros pacientes, utilizando como base o *dataset Heart Disease* [26], que também está salvo como tabela em um banco de dados. Ainda armazena os dados novos para a predição da próxima anamnese.

O algoritmo utilizado foi o *Decision Tree Classifier* que entre os algoritmos testados, apresentou os melhores resultados, chegando a um percentual de 62.58%, contra o Bagging, com 81.49%, o RandomCommittee, com 100%, e o AdaBoostM1, com 80%. Embora eles tenham uma porcentagem de correção maior, eles possuem um problema severo de *overfitting* (do inglês, sobreajuste) que faz com que se acostumem a darem uma certa resposta, enquanto com o algoritmo escolhido, o *Decision Tree Classifier*, possui um algoritmo de resultado mais realista, e com este problema bem mais reduzido. A plataforma também disponibiliza a opção do usuário treinar o Algoritmo *Decision Tree Classifier* no *dataset Heart Disease* e mostrar seu desempenho, precisão, métricas, e diversos outros dados com relação ao seu resultado de mineração do *dataset*.

Para uma compreensão mais aprofundada da arquitetura do sistema e das interações entre seus componentes, foram elaborados diagramas UML, que detalham tanto as funcionalidades do usuário quanto a estrutura interna da aplicação.

O Diagrama de Caso de Uso, apresentado na Figura 1, ilustra as principais interações entre os atores (Paciente e Profissional de Saúde) e o sistema. Ele demonstra as funcionalidades essenciais que a aplicação oferece, como a realização da anamnese, a visualização do pré-diagnóstico e a avaliação da predição da IA.

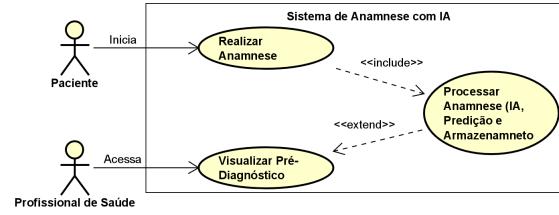


Figura 1. Diagrama de Caso de Uso do Sistema Anamnese Intuitiva Orientada por IA

Fonte: Criação do autor

Subsequentemente, a técnica de mineração de dados *Decision Tree Classifier* analisa os dados do paciente em conjunto com o *dataset* existente, assim identificando padrões e correlações. Com base nesta análise, o sistema fornece uma estimativa percentual da probabilidade do paciente apresentar uma condição cardíaca. Ao final do processo de anamnese, o sistema avalia o conjunto de respostas e apresenta ao profissional de saúde um indicativo de pré-diagnóstico, junto com os dados do paciente.

D. Scrum e Kanban

Para a gestão do projeto, usou-se os métodos de gerenciamento de projeto Scrum e Kanban. O Scrum estruturou o desenvolvimento em *Sprints* semanais de 1 hora cada, garantindo entregas incrementais de funcionalidades, como a integração da IA e a interface de anamnese. Adicionalmente, o método Kanban foi feito oralmente e informal para gerenciar o fluxo de tarefas contínuas e imprevistas, como ajustes de validação de dados, permitindo flexibilidade operacional sem a necessidade de plataformas externas ou quadros pois assim foi possível focar bem mais no desenvolvimento do projeto.

E. Arquitetura e Integração do Sistema

A arquitetura adotada segue um padrão onde a lógica de controle, os protocolos de validação e a execução dos algoritmos de Inteligência Artificial foram centralizados na camada de *Views* (visão/controle). No contexto deste projeto, as *Views* assumem a função crítica de gerenciamento de fluxo: são elas as responsáveis por receber as requisições HTTP do navegador, executar a lógica de processamento incluindo a chamada ao modelo de IA e determinar qual resposta (HTML ou JSON) deve ser retornada ao usuário.

Para viabilizar a comunicação entre o formulário web e o algoritmo *Decision Tree Classifier*, foi desenvolvido um fluxo sequencial de tratamento de dados. O processo inicia-se quando o formulário de anamnese é submetido: o sistema intercepta as variáveis (como idade, IMC, níveis de glicose) e utiliza a biblioteca *Pandas* para estruturá-las em um *DataFrame*. Esta etapa funciona como uma camada de compatibilidade, garantindo que a estrutura dos dados de entrada (colunas e tipos) seja matematicamente idêntica à utilizada durante a fase de treinamento. A Listing 1 ilustra essa captura e conversão inicial.

Listing 1. Estruturação de dados para compatibilidade com a IA

```

# 1. Estruturação dos dados vindos do formulário (Request)
# Cria-se um dicionário para mapear os inputs do HTML
data_dict = {
    'age': request.POST.get('age'),
    'bmi': request.POST.get('bmi'),
    'blood_pressure': request.POST.get('blood_pressure'),
    # (...) outros campos clínicos
}

# 2. Conversão para DataFrame (formato exigido pelo Scikit-Learn)
# O Pandas organiza os dados em colunas compatíveis com o modelo
df_paciente = pd.DataFrame([data_dict])

```

Uma vez estruturados, os dados são submetidos ao motor de inferência. Nesta fase a *View* atua como um interpretador de modelos probabilísticos. O sistema carrega para a memória RAM a estrutura da Árvore de Decisão previamente treinada (deserialização) e aplica o método *predict_proba*. Conforme demonstrado na Listing 2, essa função percorre os nós de decisão do algoritmo e calcula a probabilidade estatística do risco de doenças cardiológicas, traduzindo um dado matemático em uma classificação clínica compreensível para o profissional de saúde.

Listing 2. Execução do motor de inferência e classificação de risco

```

# 3. Execução do Motor de Inferência
# Carrega o modelo treinado (o "cérebro") e calcula a probabilidade
model = joblib.load('decision_tree_model.pkl')
prediction = model.predict_proba(df_paciente)

# Extrai-se a probabilidade da classe 1 (Positiva)
risk_score = prediction[0][1] * 100

```

```

# 4. Lógica de Processamento (Tradução para termos clínicos)
if risk_score < 40:
    risk_class = "Low"
elif 40 <= risk_score < 70:
    risk_class = "Medium"
else:
    risk_class = "High"

```

Além do fluxo de inferência, o sistema integra nativamente o pipeline de treinamento, permitindo que o modelo seja atualizado diretamente pela interface web. Quando o retreinamento é acionado, o sistema extrai o histórico de pacientes, realiza o pré-processamento reverso (codificação de variáveis categóricas) e ajusta novamente o algoritmo. Ao final, o novo modelo é serializado e salvo no disco, garantindo a persistência do aprendizado contínuo, conforme detalhado na Listing 3.

Listing 3. Rotina de Treinamento e Serialização do Modelo

```

# 1. Extração de dados históricos
queryset = DadosTreino.objects.all().values()
df = pd.DataFrame(list(queryset))

# 2. Codificação (Transformar texto em números para treino)
le = LabelEncoder()
for column in df.columns:
    if df[column].dtype == 'object':
        df[column] = le.fit_transform(df[column])

# 3. Treinamento do Algoritmo (Fit)
model = DecisionTreeClassifier(criterion='entropy')
model.fit(X_train, y_train)

# 4. Serialização (Salvar o modelo atualizado em arquivo .pkl)
joblib.dump(model, 'decision_tree_model.pkl')

```

V. RESULTADOS

A. Tela Principal

A tela principal atua como o portal de navegação central do sistema. Seu acesso é inicialmente feita pelo secretário/secretária do profissional de saúde ou pelo próprio profissional. Quando passado para o paciente responder, já está selecionada a opção Anamnese. Sua função é direcionar o usuário para realizar o registro dos seus dados. Quando acessada pelo profissional de saúde, este já pode selecionar para realizar uma anamnese, caso o paciente não o tenha feito ou a visualização de pacientes existentes (Seleção de Pacientes) ou a área de manutenção do modelo (Teste do Algoritmo).

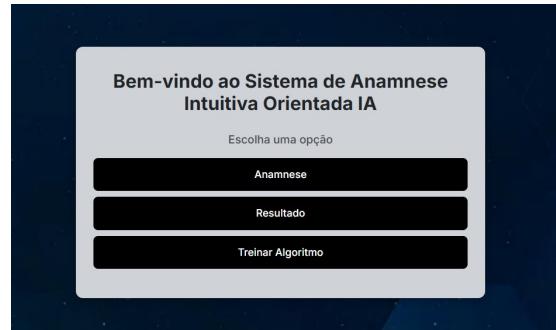


Figura 2. Tela Principal (Índice)

Fonte: Criação do autor

B. Tela de Anamnese (Coleta de Dados)

A tela de anamnese foi concebida para recolher informações abrangentes sobre o paciente, apresentando-se num formato de formulário claro e bem organizado que permite coletar informações cruciais do paciente, como se observa na Figura 3, tais como pressão arterial, IMC, tabagismo, alcoolismo entre outros. Estas informações permitem com que o sistema possa realizar o treinamento de dados.

Figura 3. Tela de Anamnese Intuitiva Orientada por IA
Fonte: Criação do autor

C. Tela de Seleção de Paciente

Esta tela, como exibida na Figura 4, serve como um ponto de entrada para a consulta dos pré-diagnósticos. Ela permite ao profissional de saúde selecionar um paciente específico a partir de uma lista suspensa, que é populada por todos os pacientes que já tiveram seus dados de anamnese registrados. Ao clicar em "Selecionar", o sistema carrega a tela de resultados com os dados correspondentes do paciente selecionado.

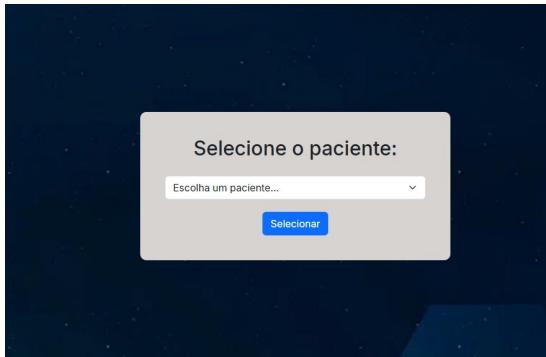


Figura 4. Tela de Seleção de Pacientes

Fonte: Criação do autor

D. Tela de Resultados da Análise de Pré-Diagnóstico

Esta tela foi desenvolvida especificamente para o profissional de saúde, apresentando uma análise detalhada baseada nos dados recolhidos na anamnese. Como se observa na Figura 5, esta tela apresenta diversas informações para o profissional da saúde, como informações do paciente e estimativa de probabilidade de doença cardíaca (Figura 6 - A). Também é possível escrever em uma caixa de texto para anotações médicas e poder alterar se o paciente realmente tem ou não doença cardíaca.

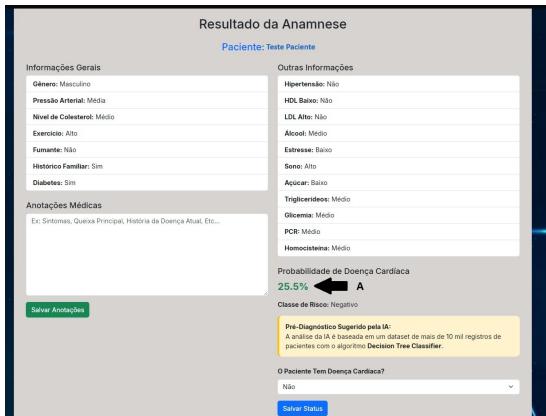


Figura 5. Tela de Resultado da Análise de Pré-Diagnóstico para o Profissional de Saúde

Fonte: Criação do autor

E. Tela de Teste e Treinamento do Modelo

Esta tela é a interface de manutenção e teste do algoritmo de *machine learning* (*DecisionTreeClassifier*). Ela permite

que o usuário (profissional de saúde) inicie o processo de treinamento do modelo, incluindo os últimos pacientes que responderam à anamnese, utilizando a base de dados atualizada dos pacientes. O botão "Treinar" aciona essa rotina, e a caixa de texto inferior é designada para exibir os resultados, como métricas de performance e logs do processo.

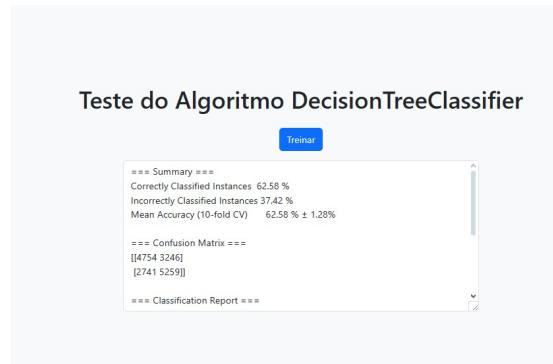


Figura 6. Tela de Teste e Treinamento do Modelo

Fonte: Criação do autor

VI. CONSIDERAÇÕES FINAIS

Com este trabalho foi possível testar diferentes algoritmos de aprendizado de máquina, em que o *Decision Tree Classifier* demonstrou ser apto a realizar as previsões com base nos dados utilizados. Com sua aplicação, foi possível treinar o modelo com base no *dataset* selecionado, assegurando análises preditivas robustas e confiáveis. Outro aspecto fundamental é a estruturação da anamnese, que é intuitiva e clara, facilitando o preenchimento pelo paciente e garantindo a padronização e integridade dos dados coletados.

Uma vez consolidados esses dados, o sistema pode aplicar o modelo treinado para gerar avaliações individualizadas, combinando as informações do paciente com os padrões identificados na base de conhecimento, podendo predizer possíveis diagnósticos com base nos dados inseridos. Como resultado final, a ferramenta buscou fornecer previsões de possíveis diagnósticos, apresentadas de forma clara e fundamentada em evidências, sem substituir o julgamento médico. Dessa forma, o sistema tem o potencial de otimizar o fluxo de trabalho clínico, oferecendo suporte decisório ágil e preciso, enquanto mantém o profissional de saúde como peça central no processo diagnóstico.

O desenvolvimento da arquitetura e integração do sistema constituiu uma das etapas mais críticas e aprofundadas do projeto, exigindo um rigoroso alinhamento entre engenharia de software e ciência de dados. A estruturação precisa dos dados (preparação), o cálculo probabilístico em tempo real (execução) e a capacidade de aprendizado contínuo (treinamento) possibilita uma viabilidade técnica da ferramenta, estabelecendo um núcleo de processamento autônomo e eficiente, essencial para a confiabilidade exigida no ambiente clínico.

A implementação dos métodos de gerenciamento de projeto desempenhou um papel crucial no projeto. A implementação

do framework *Scrum* garantiu uma organização estruturada, permitindo entregas incrementais que mantiveram o foco nas funcionalidades críticas, como a calibração do algoritmo e a usabilidade da interface. Complementarmente, a flexibilidade do método *Kanban* foi fundamental para gerenciar o fluxo de correções e ajustes de dados. Essa combinação de métodos assegurou que o desenvolvimento fosse mais adaptável às necessidades reais identificadas durante os testes.

Ressalta-se que a implementação atual se concentra no uso de aprendizado de máquina supervisionado clássico, especificamente o algoritmo *Decision Tree Classifier*, treinado com o *dataset Heart Disease*. Embora conceitos de IA Generativa e Processamento de Linguagem Natural como LLMs (*Large Language Models*), RAG (*Retrieval-Augmented Generation*), LangChain, Ollama e Whisper tenham sido abordados na fundamentação teórica e nos trabalhos correlatos, estes não foram implementados neste protótipo. Tais tecnologias foram apresentadas como base para a evolução futura da ferramenta, visando, por exemplo, permitir que o sistema interprete relatos falados ou escritos pelos pacientes em linguagem natural nas próximas versões.

Como trabalhos futuros, pode-se recomendar a criação de dois sites distintos, o primeiro em que somente o paciente tem acesso, e o segundo para um profissional de saúde logado no sistema possa acessar seus pacientes. Com também possuindo a criação de telas de login para o paciente e para o profissional de saúde. Também é possível aprofundar a implementação da segurança de dados em múltiplas camadas, abrangendo o site, o banco de dados e a infraestrutura de comunicação, para garantir a proteção robusta das informações sensíveis dos pacientes e a conformidade contínua com regulamentações como a LGPD e HIPAA, já previstas nos requisitos.

Como recomendação final, é fortemente recomendado possibilitar a troca de algoritmos de *machine learning* pelo profissional de saúde ou administrador do sistema. Poderia ser desenvolvida uma funcionalidade que permitisse selecionar e aplicar diferentes modelos (como o RandomCommittee ou AdaBoostM1, testados neste trabalho) sobre a base de dados. Isso daria flexibilidade ao profissional para buscar um modelo que, momentaneamente, possa estar oferecendo melhores resultados e precisão, conforme a base de dados de pacientes é atualizada e enriquecida.

REFERÊNCIAS

- [1] Celmo Celeno PORTO e Paulo Roberto Ribeiro COSTA. *Semiologia Médica*. 8^a ed. Rio de Janeiro: Guanabara Koogan, 2021. ISBN: 978-85-277-3498-1.
- [2] Felipe Floresti. “As doenças que mais matam no Brasil”. Em: *PESQUISA FAPESP* 336 (fev. de 2024), pp. 44–45.
- [3] Aline Camille Yehia et al. “Anamnesis in clinical practice: a review on its applications and importance”. Em: *Revista da Sociedade Brasileira de Clínica Médica* 22.2 (abr. de 2024). Publicação Trimestral - abril/junho, p. 116.
- [4] Stuart J Russell e Peter Norvig. *Artificial Intelligence: A Modern Approach*. 4^a ed. Harlow, England: Pearson, 2021.
- [5] Christopher M. Bishop. *Pattern Recognition and Machine Learning*. Information Science and Statistics. New York, NY: Springer, 2006.
- [6] Melanie Mitchell. *Artificial Intelligence: A Guide for Thinking Humans*. New York: Farrar, Straus e Giroux, 2019. ISBN: 978-0374257835.
- [7] Patrick Lewis et al. *Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks*. Acessado em: 01 de abril de 2025. 2020. URL: <https://arxiv.org/abs/2005.11401>.
- [8] Abigail M. Methley et al. *PICO, PICOS and SPIDER: a comparison study of specificity and sensitivity in three search tools for qualitative systematic reviews*. <https://doi.org/10.1186/s12913-014-0579-0>. Acessado em: 28 de abril de 2025. 2014.
- [9] Eric Matthes. *Python Crash Course: A Hands-On, Project-Based Introduction to Programming*. 2^a ed. 2^a edição, com projetos práticos em Python 3. No Starch Press, 2019. ISBN: 978-1593279288.
- [10] LANGCHAIN. *LangChain Documentation*. Acesso em: 24 abr. 2025. 2023. URL: <https://www.langchain.com/docs>.
- [11] OLLAMA. *Ollama GitHub Repository*. Acesso em: 24 abr. 2025. 2024. URL: <https://github.com/jmorganca/ollama>.
- [12] OPENAI. *Whisper: Robust Speech Recognition*. Acesso em: 24 abr. 2025. 2022. URL: <https://openai.com/research/whisper>.
- [13] HUGGING FACE. *Transformers Documentation*. Acesso em: 24 abr. 2025. 2023. URL: <https://huggingface.co/docs/transformers>.
- [14] Nils REIMERS. *Sentence-BERT: Sentence Embeddings using Siamese BERT-Networks*. Acesso em: 24 abr. 2025. 2021. URL: <https://www.sbert.net>.
- [15] Ken Schwaber e Jeff Sutherland. *The Scrum Guide*. Acesso em: 25 abr. 2025. 2020. URL: <https://www.scrumguides.org>.
- [16] David J Anderson. *Kanban: Successful Evolutionary Change for Your Technology Business*. Considerado o livro fundador do método Kanban moderno. Blue Hole Press, 2010. ISBN: 978-0984521401.
- [17] Jake VanderPlas. *Python Data Science Handbook: Essential Tools for Working with Data*. 1^a ed. Versão online disponível gratuitamente no <https://jakevdp.github.io/PythonDataScienceHandbook/>. O Reilly Media, 2016. ISBN: 978-1491912058.
- [18] OpenStreetMap contributors. *OpenStreetMap Wiki*. https://wiki.openstreetmap.org/wiki/Main_Page. Acessado em: 25 de abril de 2025. 2025.
- [19] Google LLC. *Google Maps Platform Documentation*. <https://developers.google.com/maps/documentation>. Acessado em: 25 de abril de 2025. 2025.

- [20] Meta AI. *Llama: Open and Efficient Foundation Language Models*. <https://ai.meta.com/llama/>. Acessado em: 28 de abril de 2025. 2024. URL: <https://ai.meta.com/llama/>.
- [21] World Health Organization (WHO). *Digital Health*. Acessado em: 26 abr. 2025. World Health Organization, 2023. URL: <https://www.who.int/health-topics/digital-health>.
- [22] Kerstin Denecke et al. “Self-Anamnesis with a Conversational User Interface: Concept and Usability Study”. Em: *Methods of Information in Medicine* 57.5-6 (2018), pp. 243–252. DOI: 10.1055/s-0038-1675822. URL: <https://doi.org/10.1055/s-0038-1675822>.
- [23] Brasil. *Lei Geral de Proteção de Dados (LGPD) - Lei nº 13.709/2018*. Presidência da República. Acessado em: 25 de abril de 2025. 2018. URL: http://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/lei/l13709.htm.
- [24] U.S. Department of Health e Human Services. *HIPAA Security Rule*. U.S. Department of Health & Human Services. Página oficial da HIPAA Security Rule, com orientações sobre padrões de segurança para proteção de dados de saúde eletrônicos (ePHI). 2023. URL: <https://www.hhs.gov/hipaa/for-professionals/security/index.html> (acesso em 01/11/2023).
- [25] International Organization for Standardization (ISO). *ISO/IEC 27001:2022 - Information security, cybersecurity and privacy protection — Information security management systems — Requirements*. ISO. Acessado em: 25 de abril de 2025. 2022. URL: <https://www.iso.org/standard/27001>.
- [26] Oktay Ördekçi. *Heart Disease Dataset*. <https://www.kaggle.com/datasets/oktayrdeki/heart-disease>. Acessado em: 5 de abril de 2025. 2025.
- [27] Dirce Stein Backes et al. *Software de predição de alterações de estabilidade da atenção pre-natal*. Produtos técnicos e tecnológicos em saúde materno infantil V, inovação digital, educacional e de cuidado em saúde. Pg. 69, Ed. Moria, Porto Alegre, RS. 2024.
- [28] L.B Cardoso, A.O Zamberlan e no prelo. *Módulo LLM Local em Sistema Web para Geração de Relatórios Textuais via Prompt*. Acessado em: 08 de abril de 2025. Em publicação.
- [29] Michael Hindelang, Sebastian Sitaru e Alexander Zink. *Transforming Health Care Through Chatbots for Medical History-Taking and Future Directions: Comprehensive Systematic Review*. <https://medinform.jmir.org/2024/1/e56628>. Acessado em: 08 de abril de 2025. 2024.
- [30] Gloria Marcia, Alison Liddell e Vincent Doyle. *Conversational AI with large language models to increase the uptake of clinical guidance*. Acessado em: 09 de abril de 2025. 2024.