

ALZCHECK: SISTEMA INTELIGENTE DE APOIO AO DIAGNÓSTICO PRECOCE DA DOENÇA DE ALZHEIMER**ALZCHECK: INTELLIGENT SYSTEM TO SUPPORT THE EARLY DIAGNOSIS OF ALZHEIMER'S DISEASE****ALZCHECK: SISTEMA INTELIGENTE PARA APOYAR EL DIAGNÓSTICO TEMPRANO DE LA ENFERMEDAD DE ALZHEIMER**

Letícia Maria Bandeira de Lucena¹, Luiz Fernando da Cunha Silva², Samara Martins Nascimento Gonçalves³, Verônica Maria Lima Silva⁴

e727312

<https://doi.org/10.47820/recima21.v7i2.7312>

PUBLICADO: 02/2026

RESUMO

Neste trabalho é apresentado o AlzCheck, um sistema inteligente de apoio ao diagnóstico precoce da Doença de Alzheimer, desenvolvido com foco em precisão preditiva, interpretabilidade e usabilidade clínica. O sistema utiliza um modelo supervisionado *Random Forest* para classificar pacientes com diagnóstico positivo e negativo a partir de dados clínicos estruturados, alcançando uma acurácia global de 95%. A solução é construída sobre uma arquitetura de microserviços integrada a uma API *RESTful*, com módulos independentes para autenticação, gestão de usuários, manipulação de dados médicos, predição, explicação e geração de relatórios, o que favorece escalabilidade, modularidade e segurança. Além da predição, o AlzCheck inclui um serviço de explicação textual baseado em um modelo de linguagem generativo, que traduz, em linguagem natural, os resultados da predição em descrições compreensíveis e recomendações de cuidado. Os resultados indicam que o sistema é uma ferramenta promissora para apoiar o diagnóstico precoce da Doença de Alzheimer.

PALAVRAS-CHAVE: Doença de Alzheimer. Sistema de apoio à decisão. Aprendizado de Máquina.

ABSTRACT

This work presents AlzCheck, an intelligent decision support system for early diagnosis of Alzheimer's disease, designed with emphasis on predictive performance, interpretability, and clinical usability. The system employs a supervised Random Forest model to classify patients into Non-Alzheimer and Alzheimer groups from structured clinical data, achieving an overall accuracy of 95%. The solution is built on a microservices architecture integrated through a RESTful API, with independent modules for authentication, user management, medical data handling, prediction, explanation, and report generation, which supports scalability, modularity, and secure data management. In addition to prediction, AlzCheck incorporates a textual explanation service powered by a generative language model that converts model outputs into understandable descriptions and care recommendations in natural language. The results suggest that the system is a promising tool to support the early diagnosis of Alzheimer's disease and to facilitate the integration of AI-based solutions into real clinical environments.

KEYWORDS: Alzheimer's disease. Clinical decision support system. Machine Learning.

¹ Bacharel em Sistemas de Informação pela Universidade Federal Rural do Semi-Árido - UFERSA.

² Bacharel em Sistemas de Informação pela Universidade Federal Rural do Semi-Árido - UFERSA. Pesquisador Colaborador do Instituto Tecnológico de Aeronáutica (ITA), São José dos Campos-SP.

³ Doutora em Ciência da Computação pela Universidade Federal do Ceará (UFC). Professora da Universidade Federal Rural do Semi-Árido - UFERSA, Angicos-RN.

⁴ Doutora em Engenharia Elétrica pela Universidade Federal de Campina Grande (UFCG). Professora da Universidade Federal da Paraíba (UFPB), João Pessoa-PB.

RESUMEN

Este artículo presenta AlzCheck, un sistema inteligente para el diagnóstico precoz de la enfermedad de Alzheimer, desarrollado con énfasis en la precisión predictiva, la interpretabilidad y la usabilidad clínica. El sistema utiliza un modelo de Bosque Aleatorio supervisado para clasificar a los pacientes con diagnósticos positivos y negativos basándose en datos clínicos estructurados, logrando una precisión general del 95%. La solución se basa en una arquitectura de microservicios integrada con una API RESTful, con módulos independientes para autenticación, gestión de usuarios, manipulación de datos médicos, predicción, explicación y generación de informes, lo que promueve la escalabilidad, la modularidad y la seguridad. Además de la predicción, AlzCheck incluye un servicio de explicación textual basado en un modelo de lenguaje generativo, que traduce los resultados de la predicción en descripciones comprensibles y recomendaciones de atención en lenguaje natural. Los resultados indican que el sistema es una herramienta prometedora para el diagnóstico precoz de la enfermedad de Alzheimer.

PALABRAS CLAVE: Enfermedad de Alzheimer. Sistema de apoyo a la toma de decisiones. Aprendizaje automático.

INTRODUÇÃO

A Doença de Alzheimer (DA) é uma enfermidade neurodegenerativa caracterizada pelo declínio gradual das funções cognitivas, o que afeta a memória, linguagem e capacidade de raciocínio do paciente (Gómez-Zaragoza *et al.*, 2023). Conforme exposto por Livingston *et al.* (2024), trata-se da forma mais comum de demência, sendo responsável por um impacto significativo na qualidade de vida dos pacientes, de seus familiares e dos sistemas de saúde. O envelhecimento populacional observado nas últimas décadas tem contribuído para o aumento expressivo da incidência da doença, tornando o diagnóstico precoce um dos principais desafios da prática clínica contemporânea (OMS, 2017).

Segundo Scheltens *et al.*, (2021), o diagnóstico da DA é um processo complexo, que envolve a análise clínica detalhada do paciente, a aplicação de testes cognitivos e, em alguns casos, o uso de exames complementares e biomarcadores. Entretanto, apesar dos avanços médicos, a identificação da doença em seus estágios iniciais ainda é limitada, uma vez que os sintomas podem ser sutis e facilmente confundidos com alterações cognitivas associadas ao envelhecimento natural (Scheltens *et al.*, 2021). Nesse contexto, a adoção de ferramentas computacionais capazes de auxiliar profissionais da saúde na análise de dados clínicos surge como uma alternativa promissora para apoiar a tomada de decisão médica.

A Inteligência Artificial (IA) e, em especial, o *Machine Learning* (ML), têm sido amplamente utilizados na área da saúde para a análise de grandes volumes de dados e a identificação de padrões complexos (Géron, 2021). Modelos de ML vêm sendo aplicados em tarefas como classificação de doenças, estimativa de riscos e predição de desfechos clínicos, demonstrando potencial para apoiar diagnósticos mais rápidos e precisos (Jiang *et al.*, 2017).



REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

ALZCHECK: SISTEMA INTELIGENTE DE APOIO AO DIAGNÓSTICO PRECOCE DA DOENÇA DE ALZHEIMER
 Letícia Maria Bandeira de Lucena, Luiz Fernando da Cunha Silva,
 Samara Martins Nascimento Gonçalves, Verônica Maria Lima Silva

No caso da DA, essas técnicas possibilitam a análise integrada de dados clínicos, demográficos e cognitivos, contribuindo para a identificação precoce de indivíduos em risco.

Entretanto, apesar dos avanços obtidos, muitos dos trabalhos existentes concentram-se apenas no desempenho dos modelos preditivos, negligenciando aspectos fundamentais para a adoção clínica, como a interpretabilidade dos resultados, a transparência das decisões automatizadas e a integração dessas soluções em sistemas acessíveis aos usuários finais. Dessa forma, torna-se necessária a criação de sistemas que aliem precisão preditiva, clareza na apresentação dos resultados e viabilidade de uso no contexto real da prática médica.

Com base no exposto neste trabalho, técnicas de ML são empregadas para a criação de um sistema de apoio ao diagnóstico precoce da DA, o AlzCheck. No qual, por meio do treinamento de um modelo preditivo, é realizada a predição da doença de forma automatizada, a partir dos dados clínicos do paciente referentes à doença. Além disso, o AlzCheck fornece explicações em linguagem natural sobre os resultados gerados, buscando facilitar a compreensão por parte de médicos e pacientes. Assim, esta proposta visa contribuir tanto para o meio acadêmico quanto para a prática clínica, oferecendo uma ferramenta computacional que apoia o diagnóstico precoce da DA de forma acessível, interpretável e integrada.

Este trabalho está estruturado da seguinte forma: na Seção 2 são apresentados os principais conceitos da pesquisa juntamente aos trabalhos relacionados; já na Seção 3 são expostos os métodos e tecnologias utilizadas; na Seção 4 é apresentada a modelagem do sistema; na Seção 5 são demonstradas as telas do sistema; e, por fim, na Seção 6 é discorrida a conclusão do trabalho.

1. REFERENCIAL TEÓRICO

O referencial teórico deste trabalho tem como objetivo fundamentar conceitualmente a proposta do sistema AlzCheck, apresentando os principais conceitos, definições e estudos relacionados ao diagnóstico da DA e à aplicação de técnicas de IA na área da saúde. Inicialmente, são discutidos aspectos clínicos e cognitivos da DA, bem como os desafios associados ao seu diagnóstico precoce. Em seguida, são abordados os fundamentos de IA e ML aplicados ao contexto médico. Por fim, são analisados trabalhos relacionados, destacando suas contribuições e limitações em relação à proposta apresentada neste estudo.

1.1. Doença de Alzheimer (DA) e predição cognitiva

Com o aumento da expectativa de vida da população mundial, observa-se também uma elevação significativa na incidência de doenças crônicas e neurodegenerativas, entre as quais se destaca a DA (Schilling *et al.*, 2022). Em seus estágios iniciais, a DA compromete principalmente a memória recente, com evolução gradativa para prejuízos mais amplos nas funções cognitivas,



incluindo linguagem, orientação visuoespacial e capacidade de raciocínio. Paralelamente ao declínio cognitivo, costumam surgir alterações comportamentais, como: agressividade, depressão, irritabilidade e alucinações, que afetam a autonomia e a qualidade de vida dos pacientes e de seus cuidadores (Sereniki; Vital, 2008).

A DA possui origem multifatorial, envolvendo a interação entre fatores ambientais, clínicos e genéticos. É uma condição progressiva e irreversível, influenciada por fatores como idade avançada, diabetes, hipertensão arterial e traumas cranianos, que contribuem para o declínio cognitivo e para alterações emocionais e comportamentais. Além disso, incluem-se como fatores de risco o envelhecimento, a baixa escolaridade, obesidade, sedentarismo, depressão, tabagismo, perda auditiva e isolamento social, todos associados ao aumento da vulnerabilidade à doença (Silva *et al.*, 2023; Schilling *et al.*, 2022).

O diagnóstico da Doença de Alzheimer envolve um processo clínico detalhado que combina a investigação do quadro cognitivo e funcional do paciente com a exclusão de outras causas possíveis de demência. Essa avaliação deve incluir a coleta cuidadosa da história clínica, preferencialmente com apoio de familiares ou cuidadores, onde aborda questões relacionadas a doenças preexistentes, traumas, cirurgias, uso de álcool ou outras substâncias (Aprahamian; Martinelli; Yassuda, 2009). Adicionalmente, o diagnóstico clínico da doença exige a análise dos diferentes estágios do comprometimento cognitivo e pode ser complementado por biomarcadores e exames de imagem para maior precisão, sobretudo em casos atípicos ou de início precoce (Schilling *et al.*, 2022).

Testes de rastreio cognitivos, como Mini-Exame do Estado Mental e o Teste do desenho do relógio, também são importantes para identificar *déficits* em domínios como memória, linguagem, funções executivas e habilidades visuais e espaciais. Além disso, também é necessário ocorrer a exclusão de patologias que apresentem sintomas semelhantes, garantindo uma avaliação diagnóstica mais assertiva (Aprahamian; Martinelli; Yassuda, 2009; Schilling *et al.*, 2022).

1.2. Inteligência artificial (IA) e aprendizado de máquina na saúde

A aplicação de IA na área da saúde tem avançado de maneira expressiva nos últimos anos, impulsionada, principalmente, pelo aumento da capacidade computacional, pela disponibilidade de grandes volumes de dados e pelo desenvolvimento de algoritmos capazes de aprender padrões complexos. De acordo com Russel e Norvig (2022), o termo IA se refere ao desenvolvimento de sistemas capazes de desempenhar tarefas que, normalmente, requerem inteligência humana, incluindo raciocínio, reconhecimento de padrões e tomada de decisões. No contexto médico, tais capacidades têm permitido a criação de sistemas médicos que apoiem



atividades como o diagnóstico, triagem de pacientes, detecção precoce de doenças e recomendações terapêuticas baseadas em dados (Jiang *et al.*, 2017).

Inserido no campo mais amplo da IA, o *Machine Learning* desempenha um papel central. Segundo Géron (2021), o ML é uma área da Ciência da Computação que estuda a construção de algoritmos capazes de aprender padrões a partir de dados. No contexto da saúde, esse conceito se traduz em modelos que aprendem a partir de variáveis clínicas, laboratoriais, comportamentais e demográficas para prever resultados clínicos ou estimar riscos individuais. Ademais, tal paradigma tem sido aplicado em áreas como cardiologia, oncologia, análise de imagens médicas e detecção de doenças neurodegenerativas (Esteva *et al.*, 2019).

A literatura descreve que modelos supervisionados, como a Regressão Logística (RL), *Support Vector Machines* (SVM), *Decision Trees* (DT) e Redes Neurais Artificiais (RNA), têm mostrado bom desempenho em tarefas de classificação relacionadas à progressão cognitiva e identificação de estágios iniciais da DA (Gómez-Zaragoza *et al.*, 2023, Arya *et al.*, 2023, Alatrany *et al.*, 2024). Além disso, no contexto mais recente, algoritmos baseados em *Deep Learning* (DL) vêm ganhando espaço, especialmente em aplicações envolvendo imagens de ressonância magnética, *Positron Emission Tomography* (PET) e sinais fisiológicos (Dara *et al.*, 2023, Rao *et al.*, 2023).

Apesar dos avanços, o uso da IA em ambientes clínicos requer cuidados específicos, especialmente quanto à transparência, reprodutibilidade e validação dos modelos. Shortliffe e Cimino (2014) destacam que sistemas computacionais aplicados à medicina precisam ser avaliados não apenas por métricas quantitativas de desempenho, mas também quanto à interpretabilidade e impacto na tomada de decisão médica. Desse modo, esses aspectos tornam-se ainda mais relevantes quando a previsão envolve doenças complexas e multifatoriais, como a DA, reforçando a necessidade de sistemas que combinem precisão estatística com clareza na apresentação dos resultados.

1.3. Trabalhos relacionados

Nos últimos anos, diversos estudos têm explorado o uso de técnicas de IA e ML como suporte ao diagnóstico precoce da DA, especialmente diante da necessidade de métodos mais rápidos, acessíveis e menos invasivos do que os procedimentos clínicos tradicionais.

Alatrany *et al.* (2024) sugerem uma abordagem de ML explicável para a classificação da DA, combinando múltiplos modelos tradicionais com técnicas de interpretabilidade, como o *SHapley Additive exPlanations* (SHAP). O estudo apresenta elevado desempenho preditivo e destaca a importância da explicabilidade para aumentar a confiança clínica nos sistemas baseados em IA. Entretanto, embora apresente bons resultados, o trabalho foca de modo

predominante na avaliação do modelo, sem abordar aspectos relacionados à integração do sistema em ambiente clínico real ou à interação com usuários finais, como médicos e pacientes.

Arya *et al.*, (2023) investigam o uso de técnicas de aprendizado *ensemble* para a predição da DA a partir de dados clínicos e demográficos. Os autores evidenciam que métodos *ensemble* tendem a apresentar desempenho superior quando comparados a modelos isolados, reforçando a adequação destes em cenários de classificação médica. Contudo, o estudo tem como foco a comparação de algoritmos, não contemplando uma arquitetura de sistema que permita a operacionalização prática dessas ferramentas em contextos clínicos.

Dara *et al.*, (2023) apresentam uma revisão abrangente sobre o uso de técnicas de ML e *Deep Learning* (DL) no diagnóstico da DA, destacando aplicações baseadas em imagens de ressonância magnética, PET e sinais fisiológicos. Os autores apontam que, apesar dos avanços em desempenho, muitos trabalhos enfrentam limitações relacionadas à interpretabilidade dos modelos e à dificuldade de adoção em ambientes clínicos devido à complexidade computacional e à dependência de exames de alto custo.

Outra proposta que explora modelos de ML aplicados à classificação da DA foi realizada por Rao *et al.*, (2023), que a partir de imagens 3D de ressonância magnética, obtiveram resultados promissores em termos de acurácia. Apesar disso, a abordagem depende fortemente de dados de imagem, o que pode limitar sua aplicabilidade em contextos em que tais exames não estão prontamente disponíveis, além de não fornecer mecanismos claros de explicação dos resultados para profissionais da saúde.

Outros trabalhos recentes também investigam o uso de dados alternativos, como transcrições de fala e análises linguísticas para auxiliar na detecção precoce da doença. Gómez-Zaragozá *et al.*, (2023), por exemplo, avaliam o impacto de características prosódicas e textuais na classificação da DA, demonstrando que sinais linguísticos podem contribuir de forma relevante para o diagnóstico. Ainda assim, essas abordagens tendem a atuar como ferramentas auxiliares e isoladas, não integradas a sistemas completos de apoio à decisão clínica.

Diferentemente dos trabalhos analisados, o presente estudo propõe uma abordagem integrada, que combina um modelo de ML supervisionado com uma arquitetura de microserviços e mecanismos de explicação baseados em IA generativa. Além de realizar a predição do risco de DA, o sistema oferece explicações em linguagem natural e recomendações voltadas ao paciente, promovendo maior transparência e compreensibilidade dos resultados. Assim, este estudo se posiciona como uma solução que busca atender demandas práticas da prática clínica, como interpretabilidade, acessibilidade e apoio à tomada de decisão médica.

2. MÉTODOS


Esta seção apresenta a estrutura conceitual e técnica adotada no desenvolvimento do AlzCheck, descrevendo desde os princípios arquiteturais que orientaram a construção do sistema até as ferramentas, tecnologias e fluxos operacionais que compõem sua implementação. Dessa forma, esta seção fornece uma visão sistemática do funcionamento interno da aplicação, evidenciando as decisões de engenharia que sustentam sua robustez, escalabilidade e confiabilidade no apoio ao diagnóstico da doença de Alzheimer.

2.1. Arquitetura da aplicação

A arquitetura do sistema AlzCheck foi projetada seguindo o paradigma de microsserviços, além do modelo cliente-servidor. Segundo Richards e Ford (2024), a arquitetura de microsserviços é baseada no contexto da distribuição, ou seja, “cada um dos serviços roda em seu próprio processo”. Dessa forma, tal abordagem possibilita o desenvolvimento e a implantação independente de cada módulo, o que favorece a escalabilidade, o reuso e a manutenção da aplicação. No contexto do AlzCheck, esta arquitetura foi escolhida devido à necessidade de isolamento entre os componentes responsáveis pela predição, explicabilidade e geração de relatórios, o que reduz o acoplamento e aumenta a resiliência do sistema desenvolvido.

A Figura 1 ilustra a estrutura da aplicação, a qual é composta por quatro camadas principais: a interface, a API *RESTful*, os serviços auxiliares e a base de dados. De modo geral, a interface constitui a camada de interação com o usuário, a qual foi desenvolvida em um ambiente web e permite que profissionais de saúde acessem funcionalidades de cadastro, inserção de dados clínicos, solicitação de previsões e visualização de relatórios, além de pacientes que podem acessar seus dados e acompanhar o seu diagnóstico. Ademais, esta camada se comunica exclusivamente com a API *RESTful*, o que garante a separação entre as responsabilidades de apresentação e lógica de negócios, seguindo os padrões apresentados por Richards e Ford (2024).

Figura 1. Arquitetura da Aplicação AlzCheck



Fonte: Autores.

Com relação à API *RESTful*, nota-se que esta atua como um núcleo central para a aplicação, intermediando as solicitações da interface e coordenando o fluxo de informações entre os serviços que compõem o sistema. Os módulos internos que constituem essa camada incluem: a autenticação, sendo responsável pela verificação das credenciais e controle de acesso aos recursos; o cadastro de usuários, que gerencia a criação, o armazenamento e a diferenciação de perfis de médicos e pacientes; o módulo de dados médicos, sendo responsável pela coleta, validação e persistência dos registros clínicos dos pacientes; a previsão, que encaminha os dados processados para o serviço responsável por obter o diagnóstico da doença; e a explicação IA, sendo um componente voltado à interpretabilidade do diagnóstico gerado no módulo de predição, o que permite a compreensão dos fatores que mais influenciaram no diagnóstico.

Os serviços auxiliares funcionam de forma independente, seguindo os padrões da arquitetura de microsserviços, comunicando-se com a API *RESTful* a partir de chamadas HTTP. Nesse cenário, o Serviço de Relatórios (SR) oferece uma visualização simplificada dos dados médicos do paciente, organizando-os em formatos compreensíveis e exportáveis. Além disso, o Serviço do Modelo de ML (SMML) atua como um hospedeiro para o modelo preditivo, processando as requisições recebidas e retornando os resultados inferidos. Já a API do Modelo de IA Generativa (AMIG) atua como um módulo de explicação textual, transformando as saídas do SMML em descrições interpretáveis para o usuário final, o que fortalece a transparência e a confiabilidade do sistema.

A base de dados é responsável por armazenar as informações persistentes da aplicação, incluindo os registros de usuários, pacientes, dados médicos, além do resultado da predição.

Além disso, foi adotado um modelo relacional, o que garante, segundo Silberschatz (2020), a integridade referencial e a segurança dos dados armazenados, aspectos fundamentais em sistemas que lidam com informações sensíveis, como dados médicos.

Por fim, em relação à comunicação entre os serviços, adota-se uma forma assíncrona e segura, a partir da utilização de *tokens*. Dessa forma, tal configuração permite, segundo Richards e Ford (2024), o escalonamento horizontal dos serviços, o que facilita a incorporação de novos módulos, por exemplo. Assim, a arquitetura do AlzCheck resulta em uma plataforma modular e extensível, sendo capaz de evoluir junto às demandas de pesquisa e prática clínica no contexto do diagnóstico de Alzheimer.

2.2. Ferramentas e tecnologias

O modelo de ML utilizado pelo AlzCheck foi o modelo supervisionado *Random Forest* (RF), tal modelo pertence ao grupo de métodos ensemble, ou seja, é um modelo que funciona a partir da combinação de diversas previsões obtidas para um mesmo indivíduo com a utilização de diferentes regras de previsão (Sicsú; Samartini; Barth, 2023). Esse modelo foi escolhido devido à sua alta precisão em diagnosticar os casos de controle (Não-Alzheimer) e Alzheimer da forma correta, apresentando 95% e 97% de precisão, respectivamente. Já no geral, o modelo apresentou uma acurácia de 95%.

Para o desenvolvimento do projeto, foi utilizada a linguagem *TypeScript*, sendo ela uma linguagem baseada em *JavaScript* que é estática e multiparadigma, suportando os paradigmas de orientação a objetos e programação funcional. Também foi utilizada a biblioteca *React* para a criação das interfaces de usuário (*frontend*) e o *Node* como ambiente de execução para o *backend*. Outra ferramenta importante foi o *TypeORM*, um mapeador objeto-relacional utilizado em aplicações *Node* para a manipulação do banco de dados relacionais. Além disso, também foi utilizada a linguagem *Python* para a criação dos seguintes serviços auxiliares: SR, SMML e AMIG.

Outra ferramenta utilizada foi a Cohere, que se trata de um *Large Language Model* (LLM). Essa ferramenta foi empregada para os serviços de explicação textual das previsões geradas pelo RF e, além disso, para fornecimento de recomendações de melhoria do estilo de vida dos pacientes diagnosticados com Alzheimer.

2.3. Pipeline da aplicação

O *pipeline* do AlzCheck representa o fluxo completo do processamento de informações no sistema, o que vai desde a entrada dos dados clínicos pelo profissional de saúde até a geração da predição e da explicação do diagnóstico por parte do SMML e da AMIG. De modo geral, esse *pipeline* foi projetado para ser modular, automatizado e seguro, garantindo a rastreabilidade das etapas e a integridade dos dados médicos processados.



REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

ALZCHECK: SISTEMA INTELIGENTE DE APOIO AO DIAGNÓSTICO PRECOCE DA DOENÇA DE ALZHEIMER
 Letícia Maria Bandeira de Lucena, Luiz Fernando da Cunha Silva,
 Samara Martins Nascimento Gonçalves, Verônica Maria Lima Silva

O processo é iniciado na interface web do sistema, na qual o médico, já cadastrado no sistema, realiza o registro do paciente e insere suas informações clínicas, como idade, gênero, histórico familiar, fatores cognitivos e resultados de exames complementares. A partir disso, esses dados são transmitidos para a camada da API *RESTful*, que processa e valida essas informações, além de assegurar a consistência destas e armazenar na base de dados. Em seguida, o módulo de previsão pode ser acionado pelo médico, sendo essa etapa o núcleo do *pipeline*, já que é nela que ocorre o pré-processamento dos dados e o envio das variáveis relevantes para o SMML. Assim, o modelo, previamente treinado com uma base de dados anonimizada, calcula a probabilidade de desenvolvimento da Alzheimer para aquele paciente analisado. Por fim, o resultado é então retornado à API *RESTful* que o envia de volta para a interface do usuário.

Após o cadastro do paciente, além do módulo de predição, o *pipeline* também aciona o processo do Serviço de Relatórios, o qual organiza as informações do paciente em um formato estruturado e visualmente acessível, permitindo a consulta e o *download* de relatórios individuais dos pacientes. Além disso, ao finalizar a etapa de predição, o *pipeline* ativa o módulo da Explicação IA, no qual o AMIG é utilizado para interpretar os resultados do modelo preditivo. Nesse cenário, o AMIG gera explicações em linguagem natural, destacando os principais fatores clínicos que contribuíram para a classificação obtida, além disso, essa API consegue gerar dicas de saúde que podem ser utilizadas pelo paciente no processo de manejo da doença, promovendo, desse modo, uma maior interpretabilidade e transparência no sistema. Por fim, a resposta final, composta pela predição e pela explicação textual, fica disponível na interface, onde o médico e o paciente podem visualizar o diagnóstico assistido.

3. RESULTADOS E DISCUSSÃO

A presente seção apresenta os principais resultados obtidos com o desenvolvimento e a implementação do sistema AlzCheck, bem como a discussão desses resultados à luz dos objetivos propostos neste trabalho. Inicialmente, são abordados os aspectos relacionados à modelagem do sistema, descrevendo sua estrutura e organização interna. Em seguida, são analisadas as funcionalidades da aplicação e sua contribuição como ferramenta de apoio ao diagnóstico precoce da DA, destacando seus diferenciais em termos de usabilidade, interpretabilidade e integração tecnológica.

3.1. Modelagem do Sistema

A modelagem do AlzCheck buscou representar formalmente a estrutura, os fluxos e as interações entre os componentes da aplicação. Dessa forma, por meio de diagramas e abstrações conceituais, foi possível documentar o comportamento esperado em cada módulo, garantir a coerência entre as camadas do sistema, além de orientar o processo de desenvolvimento.


ISSN: 2675-6218 - RECIMA21

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Nesta seção, são apresentados o diagrama de caso de uso e o modelo conceitual do banco de dados, que direcionaram a construção das principais telas da aplicação.

O diagrama de caso de uso do AlzCheck representa as interações entre os três tipos de usuários e as funcionalidades disponibilizadas pela aplicação. Conforme ilustrado na Figura 2, o administrador possui as ações de aprovar médicos, listar usuários e excluir contas, ou seja, funções diretamente relacionadas à gestão e ao controle do sistema. Por outro lado, o médico é o ator central no fluxo de uso, sendo responsável, após a aprovação de sua solicitação de cadastro, pelo registro de pacientes e dados clínicos, além de baixar relatórios do SR e realizar predições por meio do SMML e do AMIG, os quais fornecem estimativas e explicações sobre o risco de desenvolvimento da doença. Por fim, o paciente interage com o sistema de forma consultiva, sendo capaz de editar seus dados pessoais, visualizar os resultados das predições, além de acessar dicas de saúde geradas pelo AMIG.

Figura 2. Diagrama de caso de uso do sistema AlzCheck



Fonte: Autores.

Em relação à modelagem da base de dados, foram utilizados os princípios relacionais para estabelecer uma integridade referencial e uma rastreabilidade entre os diferentes níveis de usuários e informações clínicas que compõem o sistema. Conforme apresentado na Figura 3, o modelo é composto por cinco entidades principais: *admins*, *doctors*, *patients*, *medical_data* e *predictions*. Neste cenário, a tabela *admins* armazena as informações relacionadas aos

administradores do sistema, responsáveis pela aprovação de médicos. Estes, por sua vez, são registrados na tabela *doctors*, a qual mantém atributos como nome, e-mail e CRM, além do vínculo com o administrador que o criou.

Figura 3. Modelo conceitual do banco de dados do sistema AlzCheck




Fonte: Autores.

Ainda relacionado à modelagem da base de dados, a tabela *patients* representa os pacientes cadastrados pelos médicos, incluindo informações pessoais como data de nascimento, gênero e estado. Já a tabela *medical_data* concentra os dados clínicos coletados em exames e cadastrados pelo médico no sistema. Por fim, a tabela *predictions* registra os resultados gerados pelo SMML, associando-os a seus respectivos exames e armazenando o grau de confiança de cada predição. Em geral, essa estrutura permite a rastreabilidade completa entre administradores, médicos, pacientes e os resultados das análises clínicas, o que assegura a consistência e escalabilidade no armazenamento dos dados.

Na Figura 4 é apresentado o fluxo de atividades do AlzCheck, descrevendo o percurso operacional do sistema, o qual vai desde o cadastro de um novo médico até a obtenção dos resultados preditivos. Dessa forma, o processo é iniciado a partir da solicitação de criação de uma conta por parte do médico, que passa por uma etapa de análise e validação, a qual consiste em verificar informações que afirmam que aquele usuário é realmente um médico, conduzida pelo administrador. Caso o cadastro seja reprovado, o fluxo é encerrado. No entanto, se o cadastro for aprovado, o médico ganha acesso às funcionalidades do sistema, podendo cadastrar pacientes, inserir dados clínicos e, em seguida, realizar predições baseadas nos parâmetros fornecidos. Após o processamento, os resultados e indicadores podem ser visualizados tanto pelo médico quanto

pelo paciente, promovendo uma interpretação mais clara do estado cognitivo do indivíduo e facilitando o acompanhamento clínico. Esse fluxo reflete a sequência lógica de ações dentro do AlzCheck, garantindo controle administrativo, integridade dos dados e fluidez entre as etapas de registro, análise e visualização das predições.

Figura 4. Fluxo de atividades do sistema AlzCheck



Fonte: Autores.

3.2. AlzCheck: Uma Ferramenta para apoio ao Diagnóstico do Alzheimer

Nesta seção, é apresentada a ferramenta AlzCheck, que pode ser usada no apoio à equipe de saúde para diagnóstico do Alzheimer. Serão mostradas as funcionalidades principais do sistema, indicando os elementos essenciais da interface, bem como o seu propósito no projeto, permitindo uma melhor compreensão das interações disponíveis.


A Figura 5 apresenta a tela inicial do usuário médico, onde é possível observar um dashboard contendo os seguintes gráficos: diagnósticos por período, onde é possível aplicar filtros de tempo, predições positivas por gênero, total de pacientes nos últimos dias, e a distribuição de diagnósticos, onde seria possível analisar o total de casos positivos e negativos.



REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

ALZCHECK: SISTEMA INTELIGENTE DE APOIO AO DIAGNÓSTICO PRECOCE DA DOENÇA DE ALZHEIMER
 Letícia Maria Bandeira de Lucena, Luiz Fernando da Cunha Silva,
 Samara Martins Nascimento Gonçalves, Verônica Maria Lima Silva


Figura 5. Tela inicial do médico



Fonte: Autores.

Já a Figura 6 mostra o módulo dos pacientes para os médicos, nesta tela estão disponíveis as opções relacionadas aos pacientes: adicionar, editar, listar, inserir dados médicos e realizar predição. Outra funcionalidade importante nesta tela é a lista de pacientes, onde é mostrada uma tabela com os pacientes do médico e algumas informações importantes referentes aos pacientes, dentre elas o resultado do diagnóstico. Além disso, o quantitativo de pacientes nos últimos dias também é exibido de forma gráfica.

Figura 6. Módulo de pacientes




Fonte: Autores.

ISSN: 2675-6218 - RECIMA21

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.


A funcionalidade de cadastro de paciente é mostrada na Figura 7, onde é possível observar os dados necessários para o cadastro ser realizado. Já a Figura 8 apresenta o cadastro de dados médicos, onde são solicitados dados essenciais para a predição de Alzheimer pelo SMML.

Figura 7. Cadastro de paciente



Fonte: Autores.

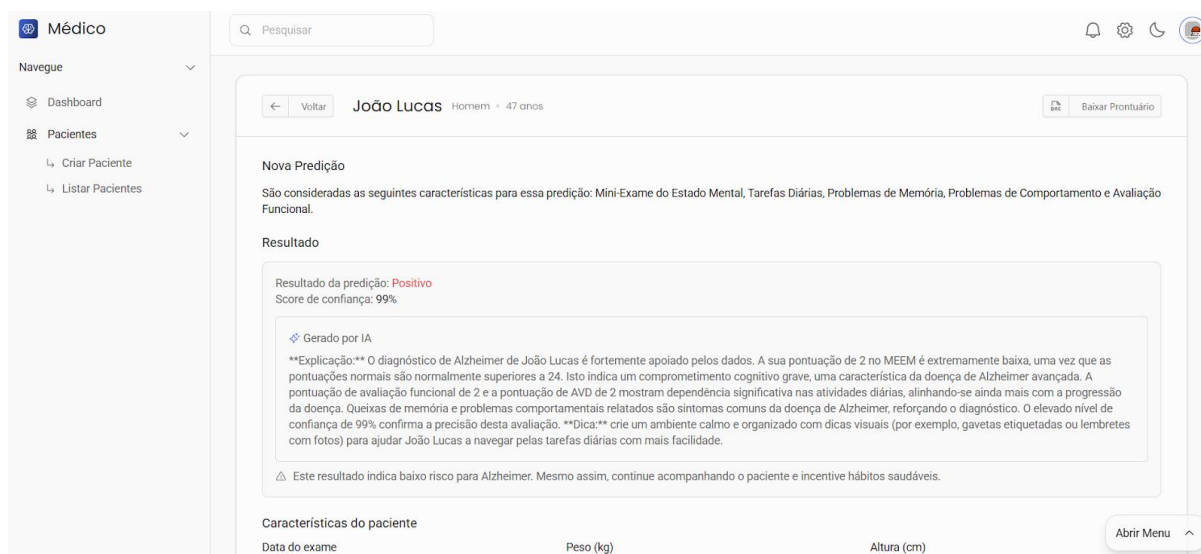
Figura 8. Cadastro de dados médicos



Fonte: Autores.

O resultado acerca do diagnóstico da doença, utilizando algoritmo de predição, é obtido a partir de dados clínicos do paciente, é exibido na Figura 9. Além do resultado da predição e de seu *score* de confiança, também é exibida uma explicação textual gerada pela AMIG, de modo a facilitar a compreensão do resultado do SMML pelo usuário final.

Figura 9. Resultado da predição



Fonte: Autores.


Na Figura 10 é apresentada a tela inicial disponível para o paciente. Nesta tela é possível observar um resumo do estado de saúde do paciente, com o resultado da predição e um gráfico demonstrando sua evolução cognitiva ao longo dos exames. Já a Figura 11 detalha o resultado obtido pelo SMML e dicas em linguagem natural geradas pela AMIG, visando auxiliar o paciente nos cuidados de sua saúde e bem-estar.



REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

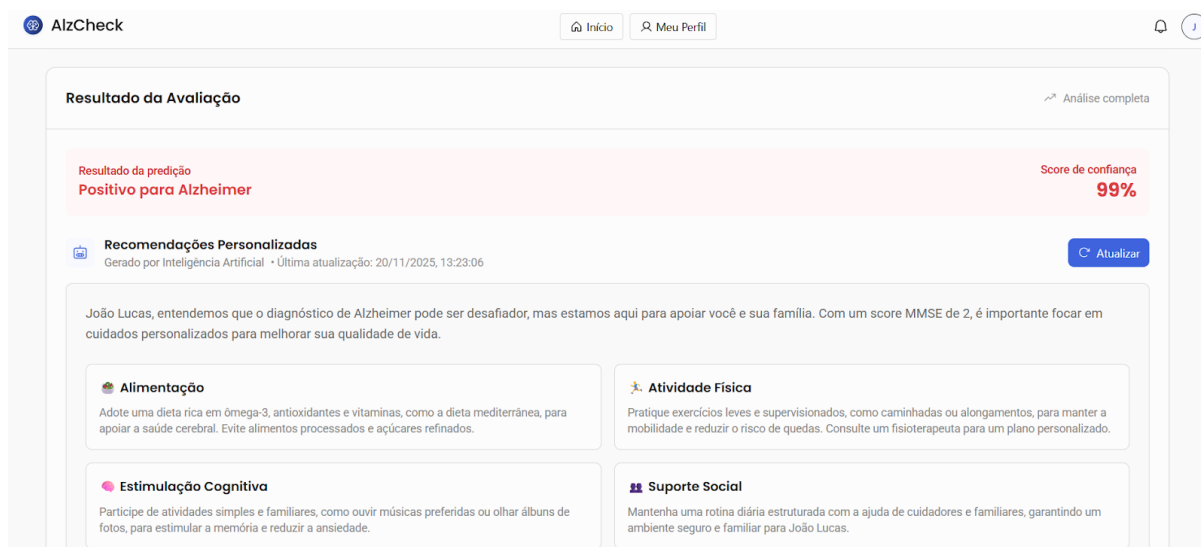
ALZCHECK: SISTEMA INTELIGENTE DE APOIO AO DIAGNÓSTICO PRECOCE DA DOENÇA DE ALZHEIMER
 Leticia Maria Bandeira de Lucena, Luiz Fernando da Cunha Silva,
 Samara Martins Nascimento Gonçalves, Verônica Maria Lima Silva

Figura 10. Tela inicial do paciente



Fonte: Autores.

Figura 11. Dicas da AMIG para o paciente



Fonte: Autores.

Desta forma, o AlzCheck é uma ferramenta que apoia o diagnóstico precoce da DA a partir da integração de diferentes funcionalidades em um único ambiente, com funções que se iniciam desde o cadastro de novos pacientes e se estendem após o diagnóstico da doença. Ou seja, além de permitir a identificação da doença, a ferramenta ainda pode contribuir com dicas para melhorias na qualidade de vida dos pacientes. Além disso, o sistema também conta com um *dashboard* que permite a visualização dos dados de forma simples e responsiva.

ISSN: 2675-6218 - RECIMA21

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.



Portanto, a junção das funcionalidades apresentadas e da interface amigável do sistema faz do AlzCheck uma ferramenta eficaz e extremamente intuitiva.

4. CONSIDERAÇÕES

Este trabalho teve como objetivo a criação de um sistema de apoio ao diagnóstico da DA através do uso de técnicas de ML, onde o processo de detecção da doença ocorreria de forma automatizada e precoce. Além disso, o sistema deveria ser preciso, intuitivo e de fácil compreensão, tanto para os médicos quanto para os pacientes assistidos pela ferramenta.

Com o estudo dos trabalhos relacionados e do embasamento teórico apresentado, foi possível notar a importância do diagnóstico precoce da DA, bem como o potencial de atrelar ML a esse processo. Nesse contexto, foi possível modelar o sistema AlzCheck conforme os requisitos necessários para que ele desempenhasse esse papel.

Desta forma, o sistema foi desenvolvido seguindo a arquitetura de microsserviços que se comunicam com a API *RESTful* principal por meio de chamadas HTTP. Dentre os serviços desenvolvidos, destacam-se: o SMML, que faz a predição da doença; o AMIG, que explica, de forma simples e textual, o resultado da predição; e, por fim, o SR, que produz relatórios simplificados dos dados do paciente. A integração desses serviços resultou em uma plataforma robusta, mas ainda assim simples, transparente e segura.

Os resultados obtidos evidenciam que o AlzCheck é capaz de apoiar o diagnóstico precoce da DA de maneira eficaz, fornecendo não apenas a predição, mas também explicações e recomendações que facilitam a compreensão dos resultados para os usuários finais. O sistema também contribui para reduzir a complexidade atrelada à interpretação dos modelos de ML.

Como trabalhos futuros, pretende-se ampliar os dados a partir da utilização de dados de imagem e dados para análises linguísticas. Além disso, propõe-se a validação do AlzCheck a partir de testes de usabilidade com profissionais da área da saúde, visando avaliar a efetividade e aceitação da ferramenta com os usuários finais.

REFERÊNCIAS

ALATRANY, A. S.; KHAN, W.; HUSSAIN, A. *et al.* An explainable machine learning approach for Alzheimer's disease classification. **Scientific Reports**, v. 14, p. 2637, 2024. Disponível em: <https://doi.org/10.1038/s41598-024-51985-w>. Acesso em: 09 out. 2024.

APRAHAMIAN, I.; MARTINELLI, J.; YASSUDA, M. Doença de Alzheimer: revisão da epidemiologia e diagnóstico. **Rev Bras Clin Med**, v. 7, p. 27–35, 2009. Disponível em: <https://docs.bvsalud.org/upload/S/1679-1010/2009/v7n1/a27-35.pdf>. Acesso em: 08 dez. 2025.

ARYA, A. D.; SINGH VERMA, S.; CHAKARABARTI, P.; BISHNOI, R. Prediction of Alzheimer's disease: A Machine Learning Perspective with Ensemble Learning. *In: International Conference On Contemporary Computing And Informatics (IC3I)*, 6., 2023, Gautam Buddha Nagar, India.

Anais [...]. Gautam Buddha Nagar: IEEE, 2023. p. 2308-2313. DOI: 10.1109/IC3I59117.2023.10397683.

DARA, O. A.; LOPEZ-GUEDE, J. M.; RAHEEM, H. I.; RAHEBI, J.; ZULUETA, E.; FERNANDEZ-GAMIZ, U. Alzheimer's Disease diagnosis using machine learning: a survey. **Applied Sciences**, v. 13, 8298, 18 jul. 2023. Disponível em: <https://doi.org/10.3390/app13148298>. Acesso em: 23 set. 2024.

ESTEVA, Andre *et al.* A guide to deep learning in healthcare. **Nature Medicine**, [s. l.], v. 25, ed. 1, p. 24-29, 2019. Disponível em: <https://doi.org/10.1038/s41591-018-0316-z>. Acesso em: 6 dez. 2025.

GÉRON, A. **Mãos à Obra: Aprendizado de Máquina com Scikit-Learn, Keras e TensorFlow**. 2. ed. atual. Rio de Janeiro: Alta Books, 2021. 614 p. ISBN 9788550815480.

GÓMEZ-ZARAGOZÁ, L.; WILLS, S.; TEJEDOR-GARCIA, C.; MARÍN-MORALES, J.; ALCAÑIZ, M.; STRIK, H. Alzheimer Disease Classification through ASR-based Transcriptions: Exploring the Impact of Punctuation and Pauses. **Interspeech**, Ireland, p. 2403-2407, 20 ago. 2023. Disponível em: <https://arxiv.org/abs/2306.03443>. Acesso em: 23 set. 2024.

JIANG, Fei *et al.* Artificial intelligence in healthcare: past, present and future. **Stroke Vasc Neurol**, [s. l.], v. 2, ed. 4, p. 230-243, 2017. Disponível em: <https://doi.org/10.1136/svn-2017-000101>. Acesso em: 6 dez. 2025.

LIVINGSTON, Gill *et al.* Dementia prevention, intervention, and care: 2024 report of the Lancet standing Commission. **The Lancet**, [s. l.], v. 404, n. 10452, p. 572-628, 10 ago. 2024. Disponível em: [https://doi.org/10.1016/S0140-6736\(24\)01296-0](https://doi.org/10.1016/S0140-6736(24)01296-0). Acesso em: 28 dez. 2025.

ORGANIZAÇÃO MUNDIAL DA SAÚDE (OMS). **Global action plan on the public health response to dementia 2017 - 2025**. Geneva: World Health Organization, 2017. 44 p. ISBN 978-92-4-151348-7. Disponível em: <https://tinyurl.com/5fdh9vzz>. Acesso em: 28 dez. 2025.

RAO, K. N.; GANDHI, B. R.; RAO, M. V.; JAVVADI, S.; VELLELA, S. S.; KHADER BASHA, S. Prediction and classification of Alzheimer's disease using machine learning techniques in 3D MR images. In: International Conference On Sustainable Computing And Smart Systems (ICSCSS), 2023, Coimbatore, Índia. **Anais [...]**. Coimbatore: IEEE, 2023. p. 85-90. DOI: 10.1109/ICSCSS57650.2023.10169550.

RICHARDS, Mark; FORD, Neal. **Fundamentos da Arquitetura de Software: Uma abordagem de engenharia**. Rio de Janeiro: Alta Books, 2024. 416 p. ISBN 9788550819853.

RUSSELL, Stuart J.; NORVIG, Peter. **Inteligência Artificial: Uma Abordagem Moderna**. 4. ed. Rio de Janeiro: GEN LTC, 2022. *E-book*. ISBN 9788595159495. Disponível em: <https://app.minhabiblioteca.com.br/reader/books/9788595159495/>. Acesso em: 06 dez. 2025.

SCHELTENS, Philip *et al.* Alzheimer's disease. **The Lancet**, [s. l.], v. 397, n. 10284, p. 1577-1590, 24 abr. 2021. Disponível em: [https://doi.org/10.1016/S0140-6736\(20\)32205-4](https://doi.org/10.1016/S0140-6736(20)32205-4). Acesso em: 4 jan. 2026.

SCHILLING, L. P. *et al.* Diagnóstico da doença de Alzheimer: recomendações do Departamento Científico de Neurologia Cognitiva e do Envelhecimento da Academia Brasileira de Neurologia. **Dementia & Neuropsychologia**, v. 16, p. 25-39, 28 nov. 2022. Disponível em: <https://www.scielo.br/j/dn/a/DYTTzwYjKYZV6KWkpBqyFXH/?lang=pt>. Acesso em: 08 dez. 2025.



REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

ALZCHECK: SISTEMA INTELIGENTE DE APOIO AO DIAGNÓSTICO PRECOCE DA DOENÇA DE ALZHEIMER
 Letícia Maria Bandeira de Lucena, Luiz Fernando da Cunha Silva,
 Samara Martins Nascimento Gonçalves, Verônica Maria Lima Silva

SERENIKI, A.; VITAL, M. A. B. F. A doença de Alzheimer: aspectos fisiopatológicos e farmacológicos. **Revista de Psiquiatria do Rio Grande do Sul**, v. 30, n. 1, 2008. Disponível em: <https://www.scielo.br/j/rprs/a/LNQzKPVKxLSsjbTnBCps4XM/?format=html&lang=pt>. Acesso em: 08 dez. 2025.

SHORTLIFFE, E. H.; CIMINO, J. J. (Org.). **Biomedical Informatics: Computer Applications in Health Care and Biomedicine**. 4. ed. Londres: Springer, 2014.

SICSÚ, Abraham L.; SAMARTINI, André; BARTH, Nelson L. **Técnicas de machine learning**. São Paulo: Editora Blucher, 2023. *E-book*. ISBN 9786555063974. Disponível em: <https://app.minhabiblioteca.com.br/reader/books/9786555063974/>. Acesso em: 26 out. 2025.

SILBERSCHATZ, Abraham. **Sistema de Banco de Dados**. 7. ed. Rio de Janeiro: GEN LTC, 2020. *E-book*. ISBN 9788595157552. Disponível em: <https://app.minhabiblioteca.com.br/reader/books/9788595157552/>. Acesso em: 23 out. 2025.

SILVA, M. R. *et al.* DOENÇA DE ALZHEIMER: ESTRATÉGIAS DE CUIDADO DIANTE DAS DIFICULDADES AO PORTADOR E CUIDADOR. **Brazilian Journal of Implantology and Health Sciences**, v. 5, n. 4, p. 164–191, 1 ago. 2023. Disponível em: <https://bjih.emnuvens.com.br/bjih/article/view/380/461>. Acesso em: 08 dez. 2025.