



Instituto Federal de Educação, Ciência e Tecnologia da Paraíba
Campus Campina Grande
Coordenação do Curso Superior de Engenharia de Computação

NeuroRay: Plataforma Inteligente para Diagnóstico Precoce da Doença de Alzheimer

Geovana Stefani Lopes Bezerra

Orientador: Elmano Ramalho Cavalcanti

Campina Grande, Junho de 2026

®Geovana Stefani Lopes Bezerra



Instituto Federal de Educação, Ciência e Tecnologia da Paraíba
Campus Campina Grande
Coordenação do Cursos Superior de Tecnologia em Telemática

NeuroRay: Plataforma Inteligente para Diagnóstico Precoce da Doença de Alzheimer

Geovana Stefani Lopes Bezerra

Monografia apresentada à Coordenação do
Curso de Engenharia de Computação do
IFPB - Campus Campina Grande, como
requisito parcial para conclusão do curso de
Bacharelado em Engenharia de Computação.

Orientador: Elmano Ramalho Cavalcanti

Campina Grande, Junho de 2026

B574n

Bezerra, Geovana Stefani Lopes

NeuroRay: Plataforma inteligente para diagnóstico precoce da doença de alzheimer - Campina Grande. Geovana Stefani Lopes Bezerra . 2026. 60f..

TCC (PDF)

Orientador: Elmano Ramalho Cavalcanti

1. Alzheimer 2. Plataforma . 3. Inteligência Artificial . I. Título II. Geovana Stefani Lopes Beserra

CDU: 004.8

NeuroRay: Plataforma Inteligente para Diagnóstico Precoce da Doença de Alzheimer

Geovana Stefani Lopes Bezerra

Elmano Ramalho Cavalcanti
Orientador

Henrique do Nascimento Cunha
Membro da Banca

Mirna Carelli Oliveira Maia
Membro da Banca

Campina Grande, Paraíba, Brasil
Junho/2026

À minha avó, Celina Lopes de Moraes.
Que me ensinou, através do amor,
que algumas lembranças podem se perder,
mas os sentimentos que realmente importam
permanecem para sempre.
Com todo o meu amor.

Agradecimentos

Agradeço, primeiramente, à minha mãe, Zilnara Lopes de Moraes, que sempre foi meu suporte ao longo de toda a vida e da minha trajetória acadêmica. Seu amor, dedicação e esforço foram fundamentais para que eu chegasse até aqui. Obrigada por sempre fazer tudo ao seu alcance para me apoiar, incentivar e acreditar em mim.

Ao meu pai, Genival Bezerra da Costa (in memoriam), que, enquanto esteve presente, me ensinou a importância dos estudos e sempre valorizou minhas conquistas acadêmicas. Seu incentivo e orgulho foram essenciais para minha formação. Você foi uma das maiores razões para que eu alcançasse este momento.

À minha irmã, Nayhara Gabriella Lopes Bezerra, por sempre reforçar a importância da educação e por me acompanhar desde os primeiros passos da minha trajetória, oferecendo apoio, incentivo e orientação.

Ao meu sobrinho, Luiz Augusto Lopes Cruz, que trouxe ainda mais alegria e leveza à minha vida e me permitiu conhecer uma forma de amor única e especial.

Aos meus avós, Celina Lopes de Moraes e José Luiz de Moraes, que sempre foram minha base, meu acolhimento e meu porto seguro. Obrigada pelo amor, cuidado e apoio incondicional ao longo de toda a minha vida.

Aos meus tios Angelita Fausto, Edmilson Moraes, Zeneide Lopes, Zoraide Lopes, Edson Moraes e Suênia Moraes, por todo o apoio e carinho. Aos meus primos Karla Layse, Carlos Alberto, Ivo Gabriel, Davi Ryan e Clarisse Micaely, e ao meu cunhado Gustavo Cruz, pelos momentos de convivência, alegria e companheirismo.

Ao Gilson Felix Gomes, por ter sido uma importante fonte de apoio durante a graduação.

Ao meu namorado, Carlos Thassius Ferreira Freire, por todo o suporte, incentivo, compreensão e confiança durante esta reta final da minha formação acadêmica. Sua presença tornou essa caminhada mais leve.

Às minhas amigas de infância Thamirys Edwiges, Gabriela Ialongo, Maria Eduarda Gomes, Eduarda Rocha, Layane Ribeiro e Maria Clara Costa, pela amizade, companheirismo e pelos inúmeros momentos de alegria compartilhados ao longo dos anos.

Aos amigos que a graduação me proporcionou, Diego Cardoso dos Santos e Emerson Ian Bezerra de Sousa, por tornarem essa trajetória mais leve e agradável.

Ao meu orientador, Prof. Dr. Elmano Ramalho Cavalcanti, pela orientação, disponibilidade, paciência e pelos ensinamentos que contribuíram para a construção deste trabalho.

Ao Prof. Dr. Henrique do Nascimento Cunha, que esteve presente durante toda a mi-

nha trajetória no IFPB, sendo uma referência profissional e oferecendo auxílio em diversos momentos importantes da minha formação.

À Profa. Dra. Mirna Carelli Oliveira Maia, pelo apoio e auxílio durante o processo de conclusão desta etapa acadêmica.

Ao Instituto Federal da Paraíba (IFPB), responsável pela minha formação técnica e superior. Ao longo destes oito anos, a instituição me proporcionou oportunidades, conhecimento e experiências que foram fundamentais para meu crescimento pessoal e profissional.

À Universidade de Coimbra, pela oportunidade proporcionada durante o período de mobilidade acadêmica, ampliando minha visão sobre pesquisa, ciência e tecnologia, além de contribuir significativamente para a definição da área que desejo seguir profissionalmente.

Por fim, agradeço à Alzheimer's Disease Neuroimaging Initiative (ADNI), bem como ao National Institute on Aging (NIH Grant U19AG024904) e às demais instituições parceiras responsáveis pelo financiamento, coleta e compartilhamento dos dados utilizados nesta pesquisa. A disponibilidade desses dados foi fundamental para a realização deste trabalho.

A todos que, de alguma forma, contribuíram para minha formação acadêmica, profissional e pessoal, meus mais sinceros agradecimentos.

Resumo

A Doença de Alzheimer é uma enfermidade neurodegenerativa progressiva que afeta milhões de pessoas em todo o mundo, comprometendo funções cognitivas essenciais e impactando significativamente a qualidade de vida dos pacientes e de seus familiares. Nesse contexto, técnicas de inteligência artificial aplicadas à análise de neuroimagens têm se destacado como ferramentas promissoras para auxiliar no diagnóstico precoce da doença. Este trabalho apresenta o desenvolvimento da plataforma NeuroRay, uma solução computacional voltada ao apoio diagnóstico da Doença de Alzheimer por meio da análise automatizada de exames de ressonância magnética e dados clínicos. Para a realização do estudo, foram utilizados dados da iniciativa Alzheimers Disease Neuroimaging Initiative (ADNI). As imagens foram processadas com a ferramenta FastSurfer para extração de características estruturais cerebrais, posteriormente utilizadas no treinamento de modelos de aprendizado de máquina. Foram avaliados os algoritmos Logistic Regression, Support Vector Machine, Random Forest e XGBoost, combinados com diferentes estratégias de seleção de atributos e validados por meio de validação cruzada estratificada. Adicionalmente, foi desenvolvida uma plataforma web para gerenciamento de pacientes, visualização de exames e geração automática de relatórios clínicos. Os resultados demonstraram que as características estruturais extraídas das imagens de ressonância magnética possuem potencial para auxiliar na identificação da Doença de Alzheimer. O melhor desempenho foi obtido pela combinação entre Recursive Feature Elimination e Logistic Regression, alcançando Recall de 0.867, Precision de 0.827, F1-Score de 0.839, Accuracy de 0,867 e ROC-AUC de 0.941. Os resultados evidenciam que a seleção adequada de características pode contribuir significativamente para o desempenho dos modelos preditivos. Conclui-se que a integração entre processamento de imagens médicas, aprendizado de máquina e sistemas computacionais pode fornecer suporte ao processo de tomada de decisão clínica, contribuindo para o desenvolvimento de ferramentas de auxílio ao diagnóstico da Doença de Alzheimer.

Palavras-chave: Doença de Alzheimer. Inteligência Artificial. Aprendizado de Máquina. Ressonância Magnética. Neuroimagem. Diagnóstico Assistido por Computador.

Abstract

Alzheimer's disease is a progressive neurodegenerative disorder that affects millions of people worldwide, impairing essential cognitive functions and significantly impacting the quality of life of patients and their families. In this context, artificial intelligence techniques applied to neuroimaging analysis have emerged as promising tools to support the early diagnosis of the disease. This work presents the development of NeuroRay, a computational platform designed to assist in the diagnosis of Alzheimer's disease through the automated analysis of magnetic resonance imaging examinations and clinical data. The study was conducted using data from the Alzheimer's Disease Neuroimaging Initiative (ADNI). The images were processed using the FastSurfer tool to extract structural brain features, which were subsequently used to train machine learning models. The algorithms evaluated included Logistic Regression, Support Vector Machine, Random Forest, and XGBoost, combined with different feature selection strategies and validated through stratified cross-validation. In addition, a web platform was developed for patient management, examination visualization, and automatic generation of clinical reports. The results demonstrated that the structural features extracted from magnetic resonance images have the potential to assist in the identification of Alzheimer's disease. The best performance was achieved by combining Recursive Feature Elimination and Logistic Regression, obtaining a Recall of 0.867, Precision of 0.827, F1-Score of 0.839, Accuracy of 0.867, and ROC-AUC of 0.941. The findings indicate that appropriate feature selection can significantly improve the predictive performance of machine learning models. It is concluded that the integration of medical image processing, machine learning, and computational systems can support clinical decision-making and contribute to the development of tools for assisting in the diagnosis of Alzheimer's disease.

Keywords: Alzheimer's Disease. Artificial Intelligence. Machine Learning. Magnetic Resonance Imaging. Neuroimaging. Computer-Aided Diagnosis.

Sumário

Lista de Abreviaturas	xii
Lista de Figuras	xiii
Lista de Tabelas	xv
1 Introdução	1
1.1 Justificativa e Relevância do Trabalho	2
1.2 Objetivos	3
1.2.1 Objetivo Geral	3
1.2.2 Objetivos Específicos	3
1.3 Metodologia	3
1.4 Organização do Documento	5
2 Fundamentação Teórica	6
2.1 Doença de Alzheimer	6
2.2 Ressonância Magnética no Diagnóstico Neurológico	7
2.3 Processamento de Imagens Médicas	7
2.4 Inteligência Artificial no Diagnóstico de Doenças Neurológicas	8
2.5 Métricas de Avaliação de Modelos de Classificação	9
3 Modelagem do Sistema	10
3.1 Visão Geral da Arquitetura	10
3.2 Diagrama de Casos de Uso	10
3.3 Modelo Conceitual	11
3.4 Diagrama de Componentes	12
3.5 Modelagem da Inteligência Artificial	13
3.5.1 Análise Clínica das Imagens	14
3.6 Diagramas de Sequência	15
3.6.1 Criação de Conta	15
3.6.2 Login	15
3.6.3 Cadastro de Paciente	16
3.6.4 Visualização de Pacientes	16

3.6.5	Visualização de Paciente Detalhado	17
3.6.6	Upload de MRI	17
3.6.7	Geração de Relatório	18
3.6.8	Visualização de Relatório	18
3.6.9	Download de Relatório em PDF	19
3.6.10	Logout	19
3.7	Considerações	19
4	Resultados e Discussão	20
4.1	Plataforma Desenvolvida	20
4.2	Construção da Base de Dados	23
4.2.1	Definição da Variável Alvo	23
4.3	Processamento das Imagens	25
4.4	Extração de Características	25
4.5	Análise Exploratória dos Dados	26
4.5.1	Configuração Experimental	26
4.5.2	Experimento 1: Utilização do Conjunto Completo de Características .	27
4.5.3	Experimento 2: Seleção de Características com SelectKBest	30
4.5.4	Experimento 3: Seleção de Características com RFE	34
4.5.5	Experimento 4: Biomarcadores Estruturais Tradicionalmente Utiliza- dos na Literatura	38
4.5.6	Comparação Geral dos Experimentos	41
5	Considerações Finais e Sugestões para Trabalhos Futuros	42
5.1	Sugestões para Trabalhos Futuros	43
	Referências Bibliográficas	45

Lista de Abreviaturas

ADNI	<i>Alzheimer's Disease Neuroimaging Initiative</i>
API	<i>Application Programming Interface</i>
AUC	<i>Area Under the Curve</i>
CNN	<i>Convolutional Neural Network</i>
DICOM	<i>Digital Imaging and Communications in Medicine</i>
DXAD	Diagnóstico de Doença de Alzheimer
DXAPROB	Diagnóstico Provável de Doença de Alzheimer
FASTAPI	<i>FastAPI Web Framework</i>
FastSurfer	<i>Fast and Accurate Deep Learning-based Neuroimaging Pipeline</i>
F1-Score	Média harmônica entre Precisão e Recall
IA	Inteligência Artificial
MCI	<i>Mild Cognitive Impairment</i> (Comprometimento Cognitivo Leve)
MRI	<i>Magnetic Resonance Imaging</i> (Ressonância Magnética)
NIFTI	<i>Neuroimaging Informatics Technology Initiative</i>
OASIS	<i>Open Access Series of Imaging Studies</i>
Precision	Precisão
Recall	Sensibilidade (<i>Recall</i>)
RFE	<i>Recursive Feature Elimination</i>
ROC	<i>Receiver Operating Characteristic</i>
ROC-AUC	Área sob a curva ROC
SVM	<i>Support Vector Machine</i>
UCSF	<i>University of California, San Francisco</i>
XGBoost	<i>Extreme Gradient Boosting</i>

Lista de Figuras

3.1	Diagrama de Casos de Uso do Sistema	11
3.2	Modelo Conceitual do Sistema	12
3.3	Diagrama de Componentes do Sistema	12
3.4	Pipeline de Processamento da Inteligência Artificial	13
3.5	Diagrama de Sequência - Criação de Conta	15
3.6	Diagrama de Sequência - Login	15
3.7	Diagrama de Sequência - Cadastro de Paciente	16
3.8	Diagrama de Sequência - Visualização de Pacientes	16
3.9	Diagrama de Sequência - Visualização Detalhada do Paciente	17
3.10	Diagrama de Sequência - Upload de MRI	17
3.11	Diagrama de Sequência - Geração de Relatório	18
3.12	Diagrama de Sequência - Visualização de Relatório	18
3.13	Diagrama de Sequência - Download de Relatório em PDF	19
3.14	Diagrama de Sequência - Logout	19
4.1	Página inicial da plataforma.	21
4.2	Listagem de pacientes disponíveis na plataforma.	21
4.3	Visualização dos dados clínicos de um paciente.	22
4.4	Exemplo de relatório gerado pela plataforma (Parte 1).	22
4.5	Exemplo de relatório gerado pela plataforma (Parte).	23
4.6	Distribuição das classes da variável alvo.	24
4.7	Visualização da ressonância magnética nos planos sagital, coronal e axial. . .	25
4.8	Distribuição da feature $Left-Lateral_{ventricle}$ extraído pelo <i>FastSurfer</i>	26
4.9	Distribuição das métricas dos modelos no Experimento 1.	27
4.10	Curvas Roc dos modelos avaliados no Experimento 1.	29
4.11	Matrizes de confusão dos modelos avaliados no Experimento 1.	30
4.12	Ranking das características selecionadas pelo SelectKBest.	31
4.13	Matrizes de confusão dos modelos avaliados no Experimento 2.	32
4.14	Matrizes de confusão dos modelos avaliados no Experimento 2.	34
4.15	Importância das características selecionadas pelo RFE.	34
4.16	Matrizes de confusão dos modelos avaliados no Experimento 3.	36

4.17	Matrizes de confusão dos modelos avaliados no Experimento 3.	37
4.18	Matrizes de confusão dos modelos avaliados no Experimento 4.	39
4.19	Matrizes de confusão dos modelos avaliados no Experimento 4.	41

Lista de Tabelas

4.1	Resultados do Experimento 1 utilizando as 46 características extraídas pelo FastSurfer.	27
4.2	Resultados do Experimento 2 utilizando as 20 características selecionadas pelo SelectKBest.	31
4.3	Resultados do Experimento 3 utilizando seleção de características por RFE. .	35
4.4	Resultados do Experimento 4 utilizando apenas sete biomarcadores estruturais clássicos.	38
4.5	Melhor resultado obtido em cada experimento.	41

Capítulo 1

Introdução

O crescimento da população idosa em escala global tem intensificado a incidência de doenças neurodegenerativas, configurando-se como um dos principais desafios contemporâneos da saúde pública. Entre essas enfermidades, destaca-se a Doença de Alzheimer, considerada a forma mais comum de demência e responsável por grande parte dos casos diagnosticados em indivíduos idosos. De acordo com Prince et al. [Prince *et al.* 2015], milhões de pessoas vivem atualmente com algum tipo de demência, e esse número tende a aumentar significativamente nas próximas décadas devido ao envelhecimento populacional.

A Doença de Alzheimer caracteriza-se por um processo progressivo de degeneração neuronal que compromete funções cognitivas essenciais, como memória, linguagem e capacidade de raciocínio. Segundo Ferri et al. [Ferri *et al.* 2005], além de impactar diretamente a qualidade de vida dos pacientes, a doença também gera efeitos socioeconômicos relevantes, afetando familiares, cuidadores e sistemas de saúde. Um dos principais desafios relacionados ao enfrentamento dessa condição é o diagnóstico tardio, que frequentemente ocorre apenas quando os sintomas já estão em estágios avançados, reduzindo significativamente as possibilidades de intervenção terapêutica.

Nesse contexto, técnicas de neuroimagem desempenham papel fundamental no diagnóstico e acompanhamento de doenças neurológicas. Entre essas técnicas, a ressonância magnética destaca-se pela capacidade de fornecer imagens detalhadas das estruturas cerebrais, permitindo identificar alterações anatômicas associadas à degeneração neuronal. Conforme descrito no *Tratado de Radiologia e Diagnóstico por Imagem* [Cerri *et al.* 2017], alterações como atrofia do hipocampo e redução do volume de determinadas regiões cerebrais podem ser observadas em exames de ressonância magnética, contribuindo para a identificação de estágios iniciais da doença.

Entretanto, a análise desses exames envolve grande complexidade e depende fortemente da interpretação de especialistas. O volume crescente de exames médicos e a necessidade de identificar padrões sutis nas imagens tornam o processo diagnóstico desafiador quando realizado exclusivamente por métodos tradicionais. Nesse cenário, avanços recentes em inteligência artificial (IA) e aprendizado de máquina têm demonstrado grande potencial para

transformar a análise de dados médicos.

Segundo a Revista FT [Uso da inteligência artificial no diagnóstico de doenças neurológicas: Doença de Alzheimer 2025], a aplicação de técnicas de inteligência artificial no diagnóstico de doenças neurológicas tem possibilitado identificar padrões complexos em exames de neuroimagem, contribuindo para diagnósticos mais rápidos e precisos. Esses sistemas são capazes de processar grandes volumes de dados clínicos e detectar anomalias que muitas vezes não são facilmente perceptíveis por análise visual humana.

Diante desse contexto, este trabalho propõe o desenvolvimento da plataforma *NeuroRay*, uma solução computacional baseada em inteligência artificial voltada para o diagnóstico assistido da Doença de Alzheimer. A plataforma tem como objetivo analisar automaticamente exames de ressonância magnética e dados clínicos, identificando padrões associados à degeneração neuronal e fornecendo suporte aos profissionais de saúde na tomada de decisão clínica.

A solução proposta integra tecnologias de inteligência artificial, processamento de imagens médicas, aprendizado de máquina e análise de dados para detectar anomalias estruturais cerebrais e gerar relatórios clínicos interpretáveis. Dessa forma, busca-se contribuir para diagnósticos mais precoces e maior precisão clínica.

Além disso, a plataforma foi projetada para atuar como ferramenta de apoio à decisão médica, não substituindo o profissional de saúde, mas ampliando sua capacidade analítica por meio do processamento automatizado de grandes volumes de dados. Espera-se que essa abordagem contribua para a redução do tempo de diagnóstico, melhoria da qualidade das decisões clínicas e otimização do fluxo de atendimento em ambientes de saúde.

1.1 Justificativa e Relevância do Trabalho

O diagnóstico precoce de doenças neurodegenerativas representa um fator essencial para o aumento da eficácia das intervenções terapêuticas e para a melhoria da qualidade de vida dos pacientes. No entanto, a identificação das fases iniciais da Doença de Alzheimer ainda representa um grande desafio para a medicina, devido à complexidade da análise de exames de neuroimagem e à necessidade de avaliação de grandes volumes de dados clínicos.

Métodos tradicionais de diagnóstico dependem majoritariamente da observação humana e da experiência clínica dos especialistas, o que pode dificultar a identificação de padrões sutis associados às fases iniciais da degeneração neuronal. Como consequência, muitos diagnósticos são realizados apenas em estágios avançados da doença, quando as opções terapêuticas são mais limitadas.

Nesse cenário, o uso de tecnologias baseadas em inteligência artificial apresenta-se como uma alternativa promissora para apoiar o processo diagnóstico. A capacidade desses sistemas de analisar grandes volumes de dados médicos e identificar padrões complexos permite ampliar o potencial de detecção precoce de anomalias cerebrais.

A relevância deste trabalho está, portanto, na possibilidade de contribuir para o desenvolvimento de ferramentas tecnológicas que auxiliem profissionais de saúde na identificação precoce da Doença de Alzheimer, promovendo diagnósticos mais rápidos, precisos e personalizados. Além disso, a proposta está alinhada às tendências atuais de inovação em saúde digital e medicina baseada em dados.

1.2 Objetivos

1.2.1 Objetivo Geral

Desenvolver uma plataforma computacional baseada em Inteligência Artificial capaz de auxiliar no diagnóstico precoce da Doença de Alzheimer por meio da análise automatizada de exames de ressonância magnética e dados clínicos.

1.2.2 Objetivos Específicos

- Investigar técnicas de aprendizado de máquina e visão computacional aplicadas à análise de neuroimagens.
- Identificar padrões e biomarcadores associados a doenças neurodegenerativas em exames médicos.
- Desenvolver um sistema capaz de detectar automaticamente anomalias estruturais cerebrais.
- Implementar mecanismos de geração de relatórios clínicos interpretáveis que auxiliem profissionais de saúde na tomada de decisão.
- Avaliar o potencial da ferramenta como suporte tecnológico para diagnósticos mais rápidos, precisos e personalizados.

1.3 Metodologia

A metodologia adotada neste trabalho envolve etapas integradas de pesquisa bibliográfica, análise de bases de dados, desenvolvimento computacional e avaliação da solução proposta. Inicialmente, foi realizada uma revisão da literatura com o objetivo de compreender os principais aspectos relacionados às doenças neurodegenerativas, com foco na Doença de Alzheimer, bem como técnicas de neuroimagem e aplicações de inteligência artificial no diagnóstico médico. Essa etapa permitiu identificar padrões relevantes observados em exames de ressonância magnética, além de orientar a escolha das técnicas computacionais mais adequadas.

Paralelamente ao levantamento teórico, foi conduzido um processo de investigação e seleção de bases de dados para utilização no treinamento dos modelos. Inicialmente, foram exploradas bases disponíveis na plataforma Kaggle, que, apesar de acessíveis, apresentaram limitações significativas, como a disponibilização de apenas uma imagem por paciente, o que inviabiliza análises mais completas baseadas em dados tridimensionais. Em seguida, foram analisadas as bases OASIS-1 e OASIS-2, que contêm exames de ressonância magnética relevantes, porém não apresentam uma categorização clara entre pacientes com Alzheimer, indivíduos saudáveis e outros tipos de demência, dificultando sua aplicação em modelos de classificação supervisionada.

Diante dessas limitações, optou-se pela utilização da base ADNI (*Alzheimers Disease Neuroimaging Initiative*) [Alzheimer's Disease Neuroimaging Initiative 2026; Weiner *et al.* 2013], uma iniciativa multicêntrica de pesquisa em neuroimagem liderada por Michael W. Weiner e coordenada pela University of California, San Francisco (UCSF). Essa base se destaca por disponibilizar imagens de ressonância magnética em formato tridimensional (3D), acompanhadas de dados clínicos estruturados e categorização diagnóstica bem definida. Além disso, a ADNI permite análises longitudinais, possibilitando o estudo da progressão da doença ao longo do tempo, o que a torna particularmente adequada para aplicações em diagnóstico assistido por computador.

Com a definição da base de dados, foram investigadas e aplicadas técnicas de processamento de imagens médicas, incluindo etapas de pré-processamento como normalização das intensidades, padronização das dimensões das imagens e organização nos planos anatômicos axial, coronal e sagital. Essas etapas são fundamentais para garantir a qualidade e consistência dos dados utilizados nos modelos de aprendizado de máquina.

A partir das imagens pré-processadas, foram consideradas características relevantes descritas na literatura, como redução do volume do hipocampo, dilatação dos ventrículos cerebrais, assimetria entre hemisférios e atrofia cortical, que são indicativas de processos neurodegenerativos. Essas informações orientaram a etapa de modelagem, na qual foram aplicados algoritmos de aprendizado de máquina supervisionado para a classificação dos exames.

Foram utilizados modelos como Logistic Regression, Random Forest, Support Vector Machine (SVM) e XGBoost, implementados com o auxílio da biblioteca Scikit-learn, além da exploração de redes neurais artificiais para análise comparativa. O objetivo desses modelos é classificar os exames em duas categorias: pacientes saudáveis e pacientes com Doença de Alzheimer.

A etapa de desenvolvimento consistiu na implementação da plataforma NeuroRay, estruturada como uma aplicação web baseada em arquitetura cliente-servidor. A interface foi desenvolvida utilizando HTML, CSS e o framework Bootstrap, enquanto o backend foi implementado em Python com o framework FastAPI, responsável pelo processamento das requisições e integração com os modelos de inteligência artificial. O armazenamento dos dados foi realizado por meio do sistema gerenciador de banco de dados MySQL.

O sistema foi projetado para realizar o processamento automatizado dos exames, desde

o upload das imagens de ressonância magnética até a geração de relatórios analíticos. Após o envio do exame, o sistema executa etapas de pré-processamento, aplica o modelo treinado e retorna um resultado que auxilia na interpretação clínica, permitindo a identificação de padrões associados à Doença de Alzheimer.

Por fim, foram analisadas as contribuições funcionais da solução, incluindo a capacidade de detecção automática de padrões em exames de neuroimagem, suporte à classificação diagnóstica e organização estruturada de dados clínicos em um ambiente digital integrado. Dessa forma, a metodologia adotada possibilita não apenas a construção de um modelo computacional, mas também sua aplicação prática em um sistema voltado ao apoio à decisão clínica.

1.4 Organização do Documento

Este trabalho está estruturado em capítulos, organizados de forma a apresentar de maneira progressiva os fundamentos teóricos, o desenvolvimento da solução proposta e os resultados obtidos.

O Capítulo 2 apresenta a fundamentação teórica, abordando conceitos relacionados à Doença de Alzheimer, técnicas de ressonância magnética, processamento de imagens médicas e aplicações de inteligência artificial no diagnóstico de doenças neurológicas.

O Capítulo 3 descreve os modelos e módulos desenvolvidos na plataforma NeuroRay, incluindo a arquitetura do sistema, os diagramas de modelagem e o pipeline de processamento das imagens médicas.

No Capítulo 4 são apresentados e analisados os resultados obtidos com a aplicação dos modelos de aprendizado de máquina, considerando métricas de desempenho e a eficácia da solução proposta.

O Capítulo 5 apresenta as considerações finais do trabalho, destacando as principais contribuições, limitações e sugestões para trabalhos futuros.

Capítulo 2

Fundamentação Teórica

Este capítulo apresenta os principais conceitos teóricos que fundamentam o desenvolvimento deste trabalho. Inicialmente, são discutidos aspectos relacionados à Doença de Alzheimer, seguidos da importância da ressonância magnética no diagnóstico de doenças neurológicas. Em seguida, são abordados conceitos de processamento de imagens médicas e, por fim, a aplicação da inteligência artificial no diagnóstico de doenças neurodegenerativas.

2.1 Doença de Alzheimer

A Doença de Alzheimer é uma enfermidade neurodegenerativa progressiva caracterizada pela deterioração gradual das funções cognitivas, especialmente memória, linguagem, orientação espacial e capacidade de raciocínio. Trata-se da forma mais comum de demência, sendo responsável por aproximadamente 60% a 70% dos casos diagnosticados mundialmente [Prince *et al.* 2015].

O avanço da doença está diretamente relacionado ao envelhecimento populacional, tornando-se um dos principais desafios de saúde pública global. Estudos epidemiológicos indicam um crescimento significativo no número de casos nas últimas décadas, com projeções de aumento contínuo nas próximas gerações [Ferri *et al.* 2005].

Do ponto de vista fisiopatológico, a Doença de Alzheimer está associada ao acúmulo anormal de proteínas no cérebro, principalmente a beta-amiloide e a proteína tau. A deposição de placas de beta-amiloide ocorre no espaço extracelular, enquanto os emaranhados neurofibrilares de tau se acumulam no interior dos neurônios, comprometendo a comunicação sináptica e levando à morte celular progressiva. Esses processos resultam em alterações estruturais e funcionais no cérebro, afetando diretamente regiões responsáveis pelas funções cognitivas [Hypothetical model of dynamic biomarkers of the Alzheimer's pathological cascade 2010; Alzheimer's disease: genes, proteins, and therapy 2001].

Entre as principais alterações estruturais observadas destacam-se a atrofia cortical progressiva, a redução do volume do hipocampo e o comprometimento do córtex temporal medial. Essas mudanças podem ser identificadas por técnicas de neuroimagem, permitindo

a análise da progressão da doença mesmo em estágios iniciais [Cerri *et al.* 2017].

O diagnóstico da Doença de Alzheimer envolve uma abordagem multidisciplinar, incluindo avaliação clínica, testes neuropsicológicos e exames de imagem. No entanto, um dos maiores desafios está na identificação precoce da doença, uma vez que os sintomas iniciais podem ser sutis e facilmente confundidos com o envelhecimento natural [Preclinical Alzheimer's disease 2016]. Nesse contexto, o uso de tecnologias computacionais surge como uma alternativa promissora para auxiliar na detecção precoce.

2.2 Ressonância Magnética no Diagnóstico Neurológico

A ressonância magnética (RM) é uma das principais ferramentas de diagnóstico por imagem utilizadas na análise de doenças neurológicas. Diferentemente de técnicas como a tomografia computadorizada, a RM não utiliza radiação ionizante, sendo considerada um método seguro e altamente eficaz para a visualização de tecidos moles [MRI from Picture to Proton 2017].

O funcionamento da RM baseia-se na interação entre campos magnéticos intensos e ondas de radiofrequência, que atuam sobre os prótons presentes nos tecidos biológicos. Os sinais gerados são captados e processados para formar imagens detalhadas das estruturas internas do corpo humano.

Uma das principais vantagens da ressonância magnética é sua alta resolução espacial e excelente contraste entre diferentes tipos de tecidos, permitindo a identificação precisa de alterações estruturais no cérebro [Cerri *et al.* 2017]. No contexto da Doença de Alzheimer, essa técnica é amplamente utilizada para detectar sinais de atrofia cerebral, especialmente em regiões associadas à memória e ao processamento cognitivo.

Entre os principais indicadores observados em exames de RM estão a redução do volume do hipocampo, a atrofia do córtex temporal medial, a dilatação dos ventrículos cerebrais e a perda de massa encefálica. Essas alterações podem ocorrer anos antes do aparecimento dos sintomas clínicos, reforçando o papel da neuroimagem no diagnóstico precoce [The clinical use of structural MRI in Alzheimer disease 2010].

Além disso, a possibilidade de obtenção de imagens em diferentes planos anatômicos axial, coronal e sagital permite uma análise mais completa da estrutura cerebral, contribuindo para uma avaliação mais detalhada das regiões afetadas.

2.3 Processamento de Imagens Médicas

O processamento de imagens médicas é uma área interdisciplinar que envolve técnicas computacionais para a análise, interpretação e manipulação de imagens digitais obtidas por exames clínicos. Essa área desempenha um papel fundamental no auxílio ao diagnóstico,

permitindo a extração de informações relevantes que não são facilmente perceptíveis por análise visual humana [Digital Image Processing 2008].

O fluxo de processamento de imagens geralmente inclui etapas como aquisição, pré-processamento, segmentação, extração de características e análise dos dados. O pré-processamento tem como objetivo melhorar a qualidade da imagem, reduzindo ruídos e padronizando características visuais. Já a segmentação permite identificar e isolar regiões de interesse, como estruturas específicas do cérebro [Current methods in medical image segmentation 2000].

A extração de características é uma etapa crucial, pois transforma informações visuais em dados numéricos que podem ser utilizados por algoritmos de aprendizado de máquina. Essas características podem incluir medidas de forma, textura, intensidade e volume das estruturas analisadas.

No contexto da Doença de Alzheimer, o processamento de imagens é amplamente utilizado para identificar padrões relacionados à degeneração cerebral, como atrofia do hipocampo e alterações nos ventrículos. Essas informações são fundamentais para o desenvolvimento de sistemas automatizados de diagnóstico.

2.4 Inteligência Artificial no Diagnóstico de Doenças Neurológicas

A inteligência artificial (IA) tem se destacado como uma ferramenta promissora no apoio ao diagnóstico médico, especialmente em áreas que envolvem grande volume de dados, como a análise de imagens médicas. Técnicas de aprendizado de máquina permitem que sistemas computacionais aprendam padrões a partir de dados previamente rotulados, possibilitando a identificação automática de anomalias [A guide to deep learning in healthcare 2019].

No diagnóstico da Doença de Alzheimer, diversos estudos têm demonstrado a eficácia de algoritmos de classificação aplicados a imagens de ressonância magnética. Modelos como Logistic Regression, Random Forest, Support Vector Machine (SVM) e XGBoost são amplamente utilizados devido à sua capacidade de lidar com dados de alta dimensionalidade [Multimodal classification of Alzheimer's disease 2011].

Além desses modelos, abordagens baseadas em redes neurais profundas têm ganhado destaque, especialmente em tarefas de reconhecimento de padrões complexos em imagens médicas [A survey on deep learning in medical image analysis 2017]. Essas técnicas permitem capturar características mais abstratas, contribuindo para o aumento da precisão diagnóstica.

A utilização de bases de dados estruturadas, como a ADNI (*Alzheimers Disease Neuroimaging Initiative*), tem sido fundamental para o avanço dessas pesquisas, fornecendo dados padronizados para treinamento e validação de modelos [The Alzheimer's Disease Neuroimaging Initiative (ADNI) 2008].

Nesse contexto, a integração entre neuroimagem, processamento de imagens e inteligên-

cia artificial representa um avanço significativo no desenvolvimento de sistemas de apoio à decisão clínica, possibilitando diagnósticos mais rápidos, precisos e consistentes.

2.5 Métricas de Avaliação de Modelos de Classificação

A avaliação de modelos de aprendizado de máquina é uma etapa fundamental para verificar sua capacidade de realizar previsões. Em problemas de classificação, diferentes métricas podem ser utilizadas para análise de desempenho, uma vez que apenas a taxa de acerto nem sempre é suficiente para representar a qualidade das predições [Sokolova e Lapalme 2009].

Uma das ferramentas mais utilizadas para essa análise é a matriz de confusão, que organiza os resultados das classificações em uma tabela contendo os verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN). A partir desses valores, diversas métricas podem ser calculadas [Powers 2011].

A acurácia (*Accuracy*) representa a proporção de classificações corretas realizadas pelo modelo em relação ao total de amostras avaliadas.

$$Accuracy = \frac{VP + VN}{VP + VN + FP + FN} \quad (2.1)$$

A precisão (*Precision*) mede a proporção de exemplos classificados como positivos que realmente pertencem à classe positiva.

$$Precision = \frac{VP}{VP + FP} \quad (2.2)$$

O recall (*Recall*), também conhecido como sensibilidade, indica a capacidade do modelo em identificar corretamente os exemplos positivos.

$$Recall = \frac{VP}{VP + FN} \quad (2.3)$$

O escore F1 (*F1-Score*) combina precisão e recall por meio da média harmônica entre essas métricas, fornecendo uma medida equilibrada do desempenho do classificador.

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (2.4)$$

Outra ferramenta amplamente utilizada é a curva ROC (*Receiver Operating Characteristic*), que avalia o comportamento do modelo em diferentes limiares de classificação. A qualidade dessa curva é frequentemente resumida pela métrica AUC (*Area Under the Curve*), cujo valor varia entre 0 e 1, sendo que valores mais próximos de 1 indicam melhor capacidade de discriminação entre as classes [Fawcett 2006].

Neste trabalho, essas métricas são utilizadas para comparar o desempenho dos modelos de aprendizado de máquina empregados na classificação de indivíduos com e sem sinais associados à Doença de Alzheimer.

Capítulo 3

Modelagem do Sistema

Este capítulo apresenta a modelagem do sistema desenvolvido, denominado *NeuroRay*. São descritos os principais diagramas que representam a estrutura, comportamento e funcionamento da plataforma, bem como as tecnologias utilizadas e o detalhamento do módulo de inteligência artificial.

3.1 Visão Geral da Arquitetura

O sistema NeuroRay foi desenvolvido como uma aplicação web baseada em arquitetura cliente-servidor, com o objetivo de auxiliar no diagnóstico precoce da Doença de Alzheimer por meio da análise de exames MRI (Magnetic Resonance Imaging - Ressonância Magnética).

A arquitetura da solução é composta por três camadas principais:

- **Frontend:** desenvolvido utilizando HTML, CSS e o framework Bootstrap, responsável pela interface com o usuário;
- **Backend:** implementado em Python utilizando o framework FastAPI, responsável pelas regras de negócio, processamento de dados e comunicação com os serviços de IA;
- **Banco de Dados:** utilizando MySQL para armazenamento persistente de informações clínicas, exames e relatórios.

Além disso, o sistema integra um módulo de inteligência artificial responsável pela análise automatizada das imagens médicas.

3.2 Diagrama de Casos de Uso

O diagrama de casos de uso, apresentado na Figura 3.1, ilustra as principais funcionalidades do sistema sob a perspectiva do usuário (médico).




Figura 3.1: *Diagrama de Casos de Uso do Sistema*

As funcionalidades principais incluem:

- Criação de conta e autenticação;
- Cadastro e gerenciamento de pacientes;
- Upload de exames de ressonância magnética;
- Geração automática de relatórios clínicos;
- Visualização e download de relatórios;
- Encerramento de sessão.

3.3 Modelo Conceitual

A Figura 3.2 apresenta o modelo conceitual do sistema, que descreve as entidades e seus relacionamentos.




Figura 3.2: *Modelo Conceitual do Sistema*

As principais entidades são:

- **Doctor:** responsável pelo uso da plataforma;
- **Patient:** armazena os dados dos pacientes;
- **ClinicalInformation:** informações clínicas associadas;
- **MRI:** exames de ressonância magnética;
- **Report:** resultados gerados pelo sistema.

O modelo permite representar a relação entre médicos, pacientes e exames, garantindo organização e integridade dos dados.

3.4 Diagrama de Componentes

A arquitetura do sistema é detalhada no diagrama de componentes da Figura 3.3.




Figura 3.3: *Diagrama de Componentes do Sistema*

O sistema segue uma separação clara de responsabilidades, onde o frontend realiza a interação com o usuário, o backend processa as requisições e o banco de dados armazena as informações.

3.5 Modelagem da Inteligência Artificial

A Figura 3.4 apresenta o pipeline de processamento utilizado para análise das imagens de ressonância magnética.




Figura 3.4: *Pipeline de Processamento da Inteligência Artificial*

O processo é composto pelas seguintes etapas:

- **Aquisição dos dados:** utilização da base pública ADNI (Alzheimer's Disease Neuroimaging Initiative);
- **Pré-processamento:** normalização das imagens, padronização de dimensões e redução de ruído;

- **Segmentação:** identificação de regiões cerebrais relevantes, especialmente o hipocampo;
- **Extração de características:** obtenção de atributos estruturais das imagens;
- **Seleção de características:** Seleção de atributos relevantes;
- **Treinamento de modelos:** aplicação de algoritmos de aprendizado de máquina;
- **Classificação:** categorização em Controle e Alzheimer.

Foram utilizados diferentes modelos de aprendizado de máquina implementados com a biblioteca *Scikit-learn*, incluindo:

- Support Vector Machine (SVM);
- Random Forest;
- Logistic Regression.
- XGboost

3.5.1 Análise Clínica das Imagens

Durante o desenvolvimento do sistema, foram considerados aspectos clínicos relevantes para a identificação de padrões associados a doenças neurodegenerativas.

A análise das imagens de ressonância magnética envolve diferentes planos anatômicos:

- **Plano axial:** permite observar o comportamento dos ventrículos cerebrais e possíveis assimetrias;
- **Plano coronal:** utilizado principalmente para análise do hipocampo;
- **Plano sagital:** auxilia na avaliação estrutural geral do cérebro.

Conforme observado nos estudos realizados, características importantes incluem:

- Assimetria entre hemisférios cerebrais;
- Dilatação ventricular;
- Redução volumétrica do hipocampo;
- Atrofia do córtex temporal e frontal;
- Presença de depósitos anormais, como beta-amiloide.

Esses padrões são fundamentais para diferenciar a Doença de Alzheimer de outras demências, como a demência frontotemporal, que apresenta maior comprometimento do córtex frontal e temporal, enquanto o Alzheimer está mais associado à atrofia hipocampal.

Dessa forma, o sistema busca automatizar a identificação dessas características por meio de técnicas computacionais.

3.6 Diagramas de Sequência

Os diagramas de sequência representam o fluxo de interação entre os componentes do sistema para cada funcionalidade implementada na plataforma NeuroRay. Esses diagramas evidenciam a comunicação entre o usuário, o backend e o banco de dados.

3.6.1 Criação de Conta




Figura 3.5: Diagrama de Sequência - Criação de Conta

Neste processo, o usuário submete seus dados, que são validados pelo backend. O sistema verifica a unicidade do e-mail, envia um token de confirmação e ativa a conta após validação.

3.6.2 Login




Figura 3.6: Diagrama de Sequência - Login

O sistema valida as credenciais do usuário, consultando o banco de dados e permitindo o acesso à plataforma em caso de sucesso.

3.6.3 Cadastro de Paciente




Figura 3.7: *Diagrama de Sequência - Cadastro de Paciente*

Os dados do paciente são enviados ao backend, validados e armazenados no banco de dados, incluindo informações clínicas associadas.

3.6.4 Visualização de Pacientes




Figura 3.8: *Diagrama de Sequência - Visualização de Pacientes*

O sistema recupera e exibe a lista de pacientes vinculados ao médico autenticado.

3.6.5 Visualização de Paciente Detalhado




Figura 3.9: *Diagrama de Sequência - Visualização Detalhada do Paciente*

São recuperadas informações completas do paciente, incluindo dados clínicos e exames realizados.

3.6.6 Upload de MRI




Figura 3.10: *Diagrama de Sequência - Upload de MRI*

O exame é enviado pelo usuário, validado pelo sistema, armazenado e registrado no banco de dados.

3.6.7 Geração de Relatório




Figura 3.11: *Diagrama de Sequência - Geração de Relatório*

O backend envia o exame para processamento pelo módulo de inteligência artificial, que executa o modelo treinado e gera o relatório clínico.

3.6.8 Visualização de Relatório




Figura 3.12: *Diagrama de Sequência - Visualização de Relatório*

O relatório armazenado é recuperado do banco de dados e exibido ao usuário.

3.6.9 Download de Relatório em PDF




Figura 3.13: *Diagrama de Sequência - Download de Relatório em PDF*

O sistema gera e disponibiliza o relatório em formato PDF para download.

3.6.10 Logout




Figura 3.14: *Diagrama de Sequência - Logout*

O sistema encerra a sessão do usuário, garantindo a segurança das informações.

3.7 Considerações

A modelagem apresentada permite uma compreensão abrangente do funcionamento do sistema NeuroRay, integrando aspectos de engenharia de software, banco de dados e inteligência artificial.

A utilização de diferentes modelos de aprendizado de máquina, aliada ao uso de dados reais de neuroimagem, contribui para o desenvolvimento de uma solução robusta e alinhada com as necessidades do diagnóstico médico assistido por computador.

Capítulo 4

Resultados e Discussão

Este capítulo apresenta os resultados obtidos durante o desenvolvimento da plataforma proposta e a avaliação dos modelos de aprendizado de máquina aplicados à detecção da Doença de Alzheimer a partir de características estruturais extraídas de exames de ressonância magnética.

Inicialmente, são apresentadas as principais funcionalidades da plataforma desenvolvida, destacando as interfaces disponibilizadas para gerenciamento de pacientes, visualização de exames e geração de relatórios clínicos. Em seguida, são descritas as etapas de construção da base de dados, incluindo o cruzamento das informações clínicas e demográficas disponibilizadas pelo ADNI, a definição da variável alvo e o processamento das imagens médicas.

Posteriormente, são apresentados os resultados da extração de características realizada pelo FastSurfer e a análise exploratória dos dados obtidos. Por fim, são discutidos os experimentos conduzidos utilizando diferentes conjuntos de atributos e estratégias de seleção de características, avaliando o desempenho dos modelos Logistic Regression, Support Vector Machine, Random Forest e XGBoost por meio de validação cruzada.

4.1 Plataforma Desenvolvida

A plataforma desenvolvida tem como objetivo centralizar o gerenciamento dos pacientes, exames de ressonância magnética e relatórios gerados pelos modelos de inteligência artificial. As interfaces foram projetadas para permitir a navegação intuitiva entre as informações clínicas e os resultados das análises realizadas.

A Figura 4.1 apresenta a Landing Page da aplicação.




Figura 4.1: Página inicial da plataforma.

Na landing page tem-se o ponto de entrada com a especificação do que é a plataforma, com acesso a demo e possibilidade de contato.

A Figura 4.2 apresenta a tela de listagem de pacientes.




Figura 4.2: Listagem de pacientes disponíveis na plataforma.

Nesta interface são exibidos os pacientes disponíveis na base de dados juntamente com informações resumidas que auxiliam na identificação dos exames cadastrados. A tela atua como mecanismo de navegação para acesso aos dados clínicos individuais.

A Figura 4.3 apresenta a visualização dos dados clínicos de um paciente.

NEURORAY

PACIENTES

João Silva

ID DO PACIENTE: 123456

IDADE / SEXO: 75 anos / M

DATA DE NASCIMENTO: 15/03/1948

DATA DE CADASTRO: 12/01/2020

Informações Clínicas

Condição Atual: Em acompanhamento neurológico

Histórico Clínico: Queixas de perda de memória leve e dificuldade de concentração

Médico Responsável: Dr. Carlos Henrique

Última Consulta: 10/04/2024

Número de exames realizados: 2

Informações de Contato

Telefone: (81) 99999-9999

Email: joaosilva@email.com

Endereço: Rua das Flores, 123 - João Pessoa - PB

Exames de Ressonância

Nome do exame: dd/mm/aaaa

Escolher arquivo: Nenhum arquivo escolhido

Adicionar

#	Nome do Exame	Data	Arquivo
1	Ressonância Magnética - Tempo 1	14/12/2018	axial1.jpg
2	Ressonância Magnética - Tempo 2	29/01/2021	axial2.jpg

Figura 4.3: Visualização dos dados clínicos de um paciente.

Nesta seção são apresentados os dados clínicos e demográficos associados ao paciente, bem como informações referentes aos exames disponíveis. Essa centralização das informações permite correlacionar os resultados produzidos pelos modelos com o histórico clínico do indivíduo.

A geração automática de relatórios constitui uma das principais funcionalidades da plataforma. A Figura 4.5 apresenta um exemplo de relatório gerado.




Figura 4.4: Exemplo de relatório gerado pela plataforma (Parte 1).




Figura 4.5: Exemplo de relatório gerado pela plataforma (Parte).

O relatório reúne as informações clínicas do paciente, os resultados da análise da ressonância magnética e as previsões realizadas pelos modelos de aprendizado de máquina. O objetivo é fornecer uma visão consolidada que possa auxiliar especialistas durante o processo de avaliação clínica.

4.2 Construção da Base de Dados

A construção da base utilizada nos experimentos exigiu o cruzamento entre os exames de ressonância magnética disponibilizados pelo projeto ADNI e os dados clínicos presentes no arquivo *DXSUM_25MAR2026*.

Inicialmente, foi realizada a correspondência entre os identificadores dos exames presentes no ADNI1 e os registros clínicos associados a cada participante. Como um mesmo indivíduo pode possuir múltiplas visitas ao longo do estudo, foi adotado o critério de utilização da visita mais recente disponível para cada paciente, permitindo que os experimentos refletissem o estado clínico mais atualizado registrado na base.

Essa decisão também evitou a presença de múltiplas observações altamente correlacionadas do mesmo indivíduo, reduzindo possíveis vieses durante o treinamento e avaliação dos modelos.

4.2.1 Definição da Variável Alvo

A variável alvo foi construída com o objetivo de representar um problema de classificação binária entre indivíduos cognitivamente saudáveis e pacientes diagnosticados com Doença de Alzheimer.

Foram atribuídos:

- Classe 0: pacientes classificados como cognitivamente normais ($DIAGNOSIS = 1$);
- Classe 1: pacientes diagnosticados com Doença de Alzheimer ($DIAGNOSIS = 3$) e que possuíam confirmação clínica nas variáveis auxiliares $DXAD = 1$ ou $DXAPROB = 1$.

Pacientes classificados com outros tipos de demência foram removidos da análise. Embora esses indivíduos estivessem presentes na base de dados, sua quantidade reduzida inviabilizaria a construção de um problema multiclasse robusto, podendo introduzir forte desbalanceamento entre as categorias e comprometer a confiabilidade das métricas obtidas.

Após o processo de filtragem foram obtidas 72 amostras, sendo 43 pertencentes à classe controle e 29 pertencentes à classe Alzheimer.

A Figura 4.6 apresenta a distribuição das classes obtidas após a construção da variável alvo.




Figura 4.6: Distribuição das classes da variável alvo.

Apesar da existência de desbalanceamento moderado entre as classes, optou-se por não aplicar técnicas de balanceamento durante os experimentos finais. Foram realizados testes utilizando estratégias de *undersampling*, porém observou-se redução da quantidade de dados disponíveis para treinamento sem ganhos consistentes de desempenho.

Considerando o tamanho reduzido da base de dados, preservar todas as amostras mostrou-se mais vantajoso do que reduzir artificialmente a quantidade de exemplos da classe majoritária.

4.3 Processamento das Imagens

Os exames de ressonância magnética foram inicialmente disponibilizados no formato DICOM (*Digital Imaging and Communications in Medicine*), padrão amplamente utilizado para armazenamento de imagens médicas.

Para possibilitar a utilização do FastSurfer, os exames foram convertidos para o formato NIfTI (*Neuroimaging Informatics Technology Initiative*), amplamente adotado em aplicações de neuroimagem por armazenar o volume tridimensional de forma mais eficiente e compatível com ferramentas de segmentação cerebral.

Após a conversão, cada exame passou a possuir dimensão volumétrica de:

$$166 \times 256 \times 256$$

representando respectivamente o número de cortes e as dimensões espaciais de cada fatia.

A Figura 4.7 apresenta exemplos dos três planos anatômicos utilizados para visualização das imagens.




Figura 4.7: Visualização da ressonância magnética nos planos sagital, coronal e axial.

A inspeção visual das imagens permitiu verificar a integridade dos exames após a conversão para NIfTI, garantindo a correta orientação anatômica antes da etapa de segmentação automática.

4.4 Extração de Características

A extração das características estruturais foi realizada utilizando o FastSurfer, ferramenta baseada em redes neurais profundas desenvolvida como alternativa computacionalmente mais eficiente ao FreeSurfer.

O FastSurfer realiza segmentação automática das estruturas cerebrais e fornece medidas volumétricas de regiões anatômicas associadas ao desenvolvimento e progressão da Doença de Alzheimer.

Foram inicialmente extraídas 46 características, incluindo volumes do hipocampo, amígdala, ventrículos, tálamo, córtex entorrinal e outras regiões frequentemente utilizadas como biomarcadores em estudos neurodegenerativos.

4.5 Análise Exploratória dos Dados

Antes da realização dos experimentos foi conduzida uma análise exploratória visando identificar inconsistências que pudessem comprometer o treinamento dos modelos.

Foram verificadas a presença de valores ausentes, registros duplicados e possíveis valores discrepantes. Não foram identificados valores nulos ou duplicações após o processo de integração das bases.

A Figura 4.8 apresenta a distribuição de uma das features extraídas.




Figura 4.8: Distribuição da feature *Left-Lateral-Ventricle* extraída pelo *FastSurfer*.

Observa-se elevada variabilidade entre as escalas dos atributos, característica esperada devido às diferenças volumétricas entre as regiões anatômicas avaliadas.

4.5.1 Configuração Experimental

Todos os experimentos foram conduzidos utilizando validação cruzada estratificada com cinco partições (*Stratified 5-Fold Cross Validation*). Essa abordagem permite que cada divisão preserve aproximadamente a proporção original das classes presentes na base de dados, reduzindo a influência de partições específicas sobre os resultados obtidos.

Para cada modelo, os hiperparâmetros foram ajustados por meio de Grid Search associado a validação cruzada com cinco partições. Dessa forma, os resultados apresentados correspondem ao desempenho médio observado ao longo das diferentes divisões dos dados.

Foram avaliados os algoritmos Logistic Regression, Support Vector Machine (SVM), Random Forest e XGBoost.

As métricas utilizadas foram Recall, Precision, F1-Score, Accuracy e ROC-AUC. Embora todas tenham sido consideradas durante a análise, o Recall recebeu maior atenção por

representar a capacidade do modelo em identificar corretamente pacientes com Doença de Alzheimer, reduzindo a ocorrência de falsos negativos.

4.5.2 Experimento 1: Utilização do Conjunto Completo de Características

O primeiro experimento teve como objetivo avaliar o desempenho dos classificadores utilizando todas as características extraídas pelo FastSurfer.

Foram utilizadas 46 variáveis relacionadas a estruturas cerebrais frequentemente associadas à progressão da Doença de Alzheimer, incluindo regiões temporais, sistema ventricular, hipocampo, amígdala e córtex entorrinal.

Esse experimento serve como linha de base para os demais cenários avaliados, permitindo verificar o impacto das técnicas de seleção de atributos empregadas posteriormente.

Tabela 4.1: Resultados do Experimento 1 utilizando as 46 características extraídas pelo FastSurfer.

Modelo	Recall	Precision	F1	Accuracy	ROC-AUC
Logistic Regression	0.867 ± 0.125	0.669 ± 0.099	0.753 ± 0.103	0.773 ± 0.090	0.867 ± 0.067
SVM	0.833 ± 0.105	0.757 ± 0.074	0.792 ± 0.084	0.827 ± 0.068	0.900 ± 0.058
Random Forest	0.800 ± 0.067	0.692 ± 0.089	0.740 ± 0.073	0.773 ± 0.068	0.852 ± 0.042
XGBoost	0.833 ± 0.105	0.667 ± 0.108	0.737 ± 0.094	0.760 ± 0.090	0.859 ± 0.065

A Figura 4.9 apresenta a distribuição das métricas obtidas durante as execuções da validação cruzada.







Figura 4.9: Distribuição das métricas dos modelos no Experimento 1.

Observa-se que o SVM apresentou não apenas desempenho médio superior, mas também menor dispersão entre as execuções, indicando maior estabilidade durante o processo de

validação cruzada.

A Regressão Logística apresentou maior variabilidade no Recall, sugerindo maior sensibilidade à composição dos subconjuntos utilizados em treinamento e teste.

A Figura 4.10 apresenta as curvas ROC dos modelos avaliados.








Figura 4.10: *Curvas Roc dos modelos avaliados no Experimento 1.*

A curva ROC evidencia a superioridade do SVM em praticamente toda a faixa de limiares de decisão, refletindo o maior valor médio de ROC-AUC obtido entre os modelos avaliados.

As matrizes de confusão obtidas para cada modelo são apresentadas na Figura 4.11.






Figura 4.11: Matrizes de confusão dos modelos avaliados no Experimento 1.

As matrizes de confusão permitem observar que os erros cometidos pelos modelos concentram-se principalmente em pacientes classificados incorretamente como saudáveis, cenário particularmente crítico em aplicações clínicas.

O SVM apresentou melhor equilíbrio entre falsos positivos e falsos negativos, justificando seu desempenho superior nas métricas globais.

4.5.3 Experimento 2: Seleção de Características com SelectKBest

O objetivo deste experimento foi investigar se a remoção de atributos menos relevantes poderia aumentar a capacidade de generalização dos modelos.

Para isso foi utilizada a técnica SelectKBest, responsável por ranquear as variáveis segundo sua relação estatística com a variável alvo. As vinte características mais relevantes foram mantidas para treinamento dos classificadores.

A Figura 4.12 apresenta o ranking gerado pelo SelectKBest.





Figura 4.12: Ranking das características selecionadas pelo SelectKBest.

Observa-se predominância de estruturas localizadas na região temporal medial e no sistema ventricular, corroborando achados frequentemente relatados na literatura sobre biomarcadores da Doença de Alzheimer.

Tabela 4.2: Resultados do Experimento 2 utilizando as 20 características selecionadas pelo SelectKBest.

Modelo	Recall	Precision	F1-Score	Accuracy	ROC-AUC
Logistic Regression	0.867 ± 0.125	0.666 ± 0.093	0.743 ± 0.063	0.760 ± 0.068	0.833 ± 0.081
SVM	0.767 ± 0.082	0.677 ± 0.117	0.711 ± 0.073	0.747 ± 0.078	0.841 ± 0.077
Random Forest	0.733 ± 0.170	0.596 ± 0.087	0.652 ± 0.110	0.693 ± 0.090	0.844 ± 0.069
XGBoost	0.700 ± 0.125	0.647 ± 0.106	0.655 ± 0.045	0.707 ± 0.053	0.841 ± 0.056









Figura 4.13: Matrizes de confusão dos modelos avaliados no Experimento 2.






Figura 4.14: Matrizes de confusão dos modelos avaliados no Experimento 2.

4.5.4 Experimento 3: Seleção de Características com RFE

Diferentemente do SelectKBest, o RFE considera o impacto conjunto das variáveis durante o treinamento dos modelos.

O método remove iterativamente os atributos menos relevantes até atingir o subconjunto final selecionado.






Figura 4.15: Importância das características selecionadas pelo RFE.

O RFE preservou estruturas tradicionalmente associadas à neurodegeneração.

Tabela 4.3: Resultados do Experimento 3 utilizando seleção de características por RFE.

Modelo	Recall	Precision	F1-Score	Accuracy	ROC-AUC
Logistic Regression	0.867 ± 0.125	0.827 ± 0.106	0.839 ± 0.089	0.867 ± 0.073	0.941 ± 0.046
SVM	0.867 ± 0.125	0.821 ± 0.112	0.838 ± 0.092	0.867 ± 0.073	0.915 ± 0.090
Random Forest	0.733 ± 0.082	0.744 ± 0.095	0.734 ± 0.071	0.787 ± 0.065	0.881 ± 0.080
XGBoost	0.667 ± 0.105	0.784 ± 0.137	0.716 ± 0.111	0.787 ± 0.088	0.867 ± 0.074







Figura 4.16: Matrizes de confusão dos modelos avaliados no Experimento 3.






Figura 4.17: Matrizes de confusão dos modelos avaliados no Experimento 3.

Os resultados obtidos neste experimento representam o melhor desempenho observado em todo o estudo.

A combinação entre RFE e Regressão Logística alcançou Recall de 0.867 e Precision de 0.827, resultando em F1-Score de 0.839.

Diferentemente do Experimento 2, a seleção realizada pelo RFE não avaliou cada variável isoladamente. O método considerou o impacto das características durante o treinamento do modelo, preservando atributos que, embora possuam menor relevância individual, contribuem significativamente quando analisados em conjunto.

Esse comportamento pode explicar o aumento simultâneo de Recall, Precision e ROC-AUC observado neste cenário.


4.5.5 Experimento 4: Biomarcadores Estruturais Tradicionalmente Utilizados na Literatura

O último experimento teve como objetivo avaliar se apenas os biomarcadores estruturais mais frequentemente utilizados em estudos sobre Doença de Alzheimer seriam suficientes para alcançar desempenho comparável aos experimentos anteriores.

Foram selecionadas sete estruturas amplamente reportadas na literatura como marcadores de neurodegeneração: Left-Hippocampus, Right-Hippocampus, Left-Lateral-Ventricle, Right-Lateral-Ventricle, 3rd-Ventricle, 4th-Ventricle e Brain-Stem

Tabela 4.4: Resultados do Experimento 4 utilizando apenas sete biomarcadores estruturais clássicos.

Modelo	Recall	Precision	F1-Score	Accuracy	ROC-AUC
Logistic Regression	0.767 ± 0.133	0.736 ± 0.164	0.734 ± 0.085	0.773 ± 0.090	0.867 ± 0.112
SVM	0.867 ± 0.125	0.669 ± 0.089	0.753 ± 0.096	0.773 ± 0.090	0.881 ± 0.089
Random Forest	0.700 ± 0.245	0.586 ± 0.149	0.634 ± 0.186	0.693 ± 0.137	0.815 ± 0.070
XGBoost	0.600 ± 0.133	0.578 ± 0.067	0.585 ± 0.089	0.667 ± 0.060	0.769 ± 0.080









Figura 4.18: Matrizes de confusão dos modelos avaliados no Experimento 4.






Figura 4.19: Matrizes de confusão dos modelos avaliados no Experimento 4.

4.5.6 Comparação Geral dos Experimentos

Tabela 4.5: Melhor resultado obtido em cada experimento.

Experimento	Modelo	Recall	Precision	F1	Accuracy	ROC-AUC
Exp. 1	SVM	0.833	0.757	0.792	0.827	0.900
Exp. 2	Logistic	0.867	0.666	0.743	0.760	0.833
Exp. 3	Logistic	0.867	0.827	0.839	0.867	0.941
Exp. 4	SVM	0.867	0.669	0.753	0.773	0.881

A comparação geral evidencia que a simples redução do número de atributos não garante melhoria de desempenho.

O SelectKBest apresentou redução consistente das métricas quando comparado ao conjunto completo de características, sugerindo perda de informações relevantes.

Por outro lado, o RFE produziu ganhos simultâneos em Recall, Precision, F1-Score e ROC-AUC, indicando que a eliminação de atributos redundantes foi realizada de forma mais eficiente.

Os resultados também demonstram que a utilização exclusiva dos biomarcadores mais conhecidos da literatura não foi suficiente para reproduzir o desempenho observado quando características complementares foram incorporadas ao modelo.

Dessa forma, os experimentos sugerem que a combinação de múltiplas estruturas cerebrais fornece representação mais abrangente das alterações anatômicas associadas à Doença de Alzheimer.

Capítulo 5

Considerações Finais e Sugestões para Trabalhos Futuros

O presente trabalho teve como objetivo desenvolver uma plataforma para apoio à análise da Doença de Alzheimer a partir de exames de ressonância magnética, integrando processamento de imagens médicas, extração automatizada de características estruturais, aplicação de modelos de aprendizado de máquina e geração de relatórios clínicos.

Para atingir esse objetivo, foi realizada a construção de uma base de dados a partir da integração entre exames de ressonância magnética e informações clínicas disponibilizadas pelo projeto ADNI. Os exames foram processados utilizando a ferramenta FastSurfer, responsável pela segmentação automática das estruturas cerebrais e extração de medidas volumétricas utilizadas como atributos para os modelos de classificação.

Além da etapa de análise preditiva, foi desenvolvida uma plataforma web capaz de centralizar informações dos pacientes, disponibilizar dados clínicos e exames processados, bem como gerar relatórios contendo os resultados das análises realizadas. Dessa forma, o trabalho contemplou tanto aspectos computacionais relacionados à inteligência artificial quanto questões voltadas à organização e visualização das informações clínicas.

Os experimentos realizados demonstraram que as características estruturais extraídas de exames de ressonância magnética possuem potencial para auxiliar na identificação da Doença de Alzheimer. Entre os modelos avaliados, os melhores resultados foram obtidos pela combinação entre seleção de características por RFE e Regressão Logística, alcançando Recall de 0,867, Precision de 0.827, F1-Score de 0.839, Accuracy de 0.867 e ROC-AUC de 0.941.

Os resultados também evidenciaram que a estratégia de seleção de atributos exerce influência significativa sobre o desempenho dos modelos. Enquanto a abordagem baseada em SelectKBest apresentou redução nas métricas quando comparada ao conjunto completo de características, o método RFE foi capaz de identificar um subconjunto mais representativo de atributos, preservando relações relevantes entre diferentes estruturas cerebrais. Esse comportamento reforça a importância de considerar não apenas a relevância individual das

variáveis, mas também suas contribuições conjuntas para o processo de classificação.

Outro resultado relevante foi a constatação de que a utilização exclusiva dos biomarcadores tradicionalmente empregados na literatura não foi suficiente para alcançar o melhor desempenho observado. Isso sugere que alterações anatômicas associadas à Doença de Alzheimer estão distribuídas em múltiplas regiões cerebrais e que a incorporação de características complementares pode contribuir para uma representação mais abrangente do processo neurodegenerativo.

Apesar dos resultados promissores, algumas limitações devem ser consideradas. A principal delas está relacionada ao tamanho reduzido da amostra utilizada nos experimentos, consequência dos critérios adotados para seleção e integração dos dados clínicos e de imagem. Embora a validação cruzada tenha sido empregada para aumentar a confiabilidade da avaliação, estudos com bases maiores podem fornecer estimativas mais robustas da capacidade de generalização dos modelos desenvolvidos.

De maneira geral, os resultados obtidos demonstram a viabilidade da utilização de técnicas de aprendizado de máquina associadas à análise estrutural de imagens de ressonância magnética como ferramenta de apoio à identificação da Doença de Alzheimer, além de evidenciar o potencial de integração dessas técnicas em plataformas computacionais voltadas ao contexto clínico.

5.1 Sugestões para Trabalhos Futuros

Como continuidade deste trabalho, recomenda-se a ampliação da base de dados utilizada nos experimentos. O projeto ADNI encontra-se em constante expansão desde 2003 e disponibiliza um volume significativamente maior de informações clínicas, demográficas, cognitivas e de neuroimagem do que o conjunto explorado nesta pesquisa. A incorporação de um número maior de participantes poderá aumentar a robustez estatística dos experimentos e possibilitar a avaliação de modelos mais complexos.

Outra possibilidade consiste na inclusão de pacientes classificados em estágios intermediários, como Comprometimento Cognitivo Leve (*Mild Cognitive Impairment MCI*), permitindo a construção de problemas multiclasse e análises mais próximas dos cenários encontrados na prática clínica.

Além disso, uma direção promissora é a exploração da natureza longitudinal dos dados disponibilizados pelo ADNI. Neste trabalho foi utilizada apenas a visita mais recente de cada participante, porém muitos pacientes possuem diversas avaliações realizadas ao longo dos anos. A utilização dessas informações temporais permitiria investigar a progressão da doença, identificar padrões de evolução clínica e desenvolver modelos capazes de prever a conversão de indivíduos cognitivamente normais ou com comprometimento cognitivo leve para estágios mais avançados da Doença de Alzheimer.

Também podem ser exploradas abordagens baseadas em aprendizado profundo, utili-

zando diretamente os volumes tridimensionais das imagens de ressonância magnética, bem como estratégias multimodais que integrem dados de neuroimagem, testes cognitivos, informações genéticas e biomarcadores clínicos.

Adicionalmente, estudos futuros poderão investigar o impacto da utilização da NeuroRay no processo de tomada de decisão médica, comparando métricas como tempo de análise, concordância diagnóstica entre especialistas e confiança na interpretação dos exames quando comparadas abordagens com e sem suporte da plataforma.

Por fim, sugere-se a evolução da plataforma desenvolvida para suportar análises longitudinais, visualização da evolução temporal dos pacientes e comparação automática entre exames realizados em diferentes momentos, ampliando seu potencial de aplicação em contextos de pesquisa e apoio à decisão clínica.

Referências Bibliográficas

[A guide to deep learning in healthcare 2019] A guide to deep learning in healthcare. *Nature Medicine*, 2019.

[A survey on deep learning in medical image analysis 2017] A survey on deep learning in medical image analysis. *Medical Image Analysis*, 2017.

[Alzheimer’s disease: genes, proteins, and therapy 2001] ALZHEIMER’S disease: genes, proteins, and therapy. *Physiological Reviews*, 2001.

[Alzheimer’s Disease Neuroimaging Initiative 2026] Alzheimer’s Disease Neuroimaging Initiative. *ADNI Database*. 2026. Acesso em: 04 jun. 2026. Disponível em: <<https://adni.loni.usc.edu/>>.

[Cerri *et al.* 2017] CERRI, G. G. *et al.* (Ed.). *Tratado de Radiologia e Diagnóstico por Imagem*. [S.l.]: Elsevier, 2017.

[Current methods in medical image segmentation 2000] CURRENT methods in medical image segmentation. *Annual Review*, 2000.

[Digital Image Processing 2008] DIGITAL Image Processing. [S.l.: s.n.], 2008.

[Fawcett 2006] FAWCETT, T. An introduction to roc analysis. *Pattern Recognition Letters*, v. 27, n. 8, p. 861–874, 2006.

[Ferri *et al.* 2005] FERRI, C. P. *et al.* Global prevalence of dementia: a delphi consensus study. *The Lancet*, v. 366, n. 9503, p. 2112–2117, 2005.

[Hypothetical model of dynamic biomarkers of the Alzheimer’s pathological cascade 2010] HYPOTHETICAL model of dynamic biomarkers of the Alzheimer’s pathological cascade. *Lancet Neurology*, 2010.

[MRI from Picture to Proton 2017] MRI from Picture to Proton. [S.l.: s.n.], 2017.

[Multimodal classification of Alzheimer’s disease 2011] MULTIMODAL classification of Alzheimer’s disease. *NeuroImage*, 2011.

[Powers 2011] POWERS, D. M. W. Evaluation: From precision, recall and f-measure to roc, informedness, markedness and correlation. *Journal of Machine Learning Technologies*, v. 2, n. 1, p. 37–63, 2011.

[Preclinical Alzheimer’s disease 2016] PRECLINICAL Alzheimer’s disease. *Lancet Neurology*, 2016.

[Prince *et al.* 2015] PRINCE, M. *et al.* The burden of disease in older people and implications for health policy and practice. *The Lancet*, v. 385, n. 9967, p. 549–562, 2015.

[Sokolova e Lapalme 2009] SOKOLOVA, M.; LAPALME, G. A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, v. 45, n. 4, p. 427–437, 2009.

[The Alzheimer’s Disease Neuroimaging Initiative (ADNI) 2008] THE Alzheimer’s Disease Neuroimaging Initiative (ADNI). *NeuroImage*, 2008.

[The clinical use of structural MRI in Alzheimer disease 2010] THE clinical use of structural MRI in Alzheimer disease. *Nature Reviews Neurology*, 2010.

[Uso da inteligência artificial no diagnóstico de doenças neurológicas: Doença de Alzheimer 2025] USO da inteligência artificial no diagnóstico de doenças neurológicas: Doença de Alzheimer. 2025. Disponível em: <<https://revistaft.com.br/uso-da-inteligencia-artificial-no-diagnostico-de-doencas-neurologicas-doenca-de-alzheimer/>>.

[Weiner *et al.* 2013] WEINER, M. W. *et al.* The alzheimer’s disease neuroimaging initiative: A review of papers published since its inception. *Alzheimer’s & Dementia*, v. 9, n. 5, p. e111–e194, 2013.



INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DA PARAÍBA
Campus Campina Grande - Código INEP: 25137409
R. Tranquílino Coelho Lemos, 671, Dinamérica, CEP 58432-300, Campina Grande (PB)
CNPJ: 10.783.898/0003-37 - Telefone: (83) 2102.6200

Documento Digitalizado Ostensivo (Público)

TCC Final

Assunto:	TCC Final
Assinado por:	Geovana Bezerra
Tipo do Documento:	Projeto
Situação:	Finalizado
Nível de Acesso:	Ostensivo (Público)
Tipo do Conferência:	Cópia Simples

Documento assinado eletronicamente por:

- **Geovana Stefani Lopes Bezerra, DISCENTE (202111250032) DE BACHARELADO EM ENGENHARIA DE COMPUTAÇÃO - CAMPINA GRANDE**, em 24/07/2026 15:53:58.

Este documento foi armazenado no SUAP em 24/07/2026. Para comprovar sua integridade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifpb.edu.br/verificar-documento-externo/> e forneça os dados abaixo:

Código Verificador: 1924775

Código de Autenticação: 481dc2bf35

