



UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA - CCET
ENGENHARIA DA COMPUTAÇÃO

Leonardo Lima Castelo Branco

**Classificação de níveis neurodegenerativos
utilizando *deep learning***

São Luís - MA

2025

Leonardo Lima Castelo Branco

Classificação de níveis neurodegenerativos utilizando *deep learning*

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia da Computação da Universidade Federal do Maranhão como requisito parcial para a obtenção do grau de Bacharel em Engenharia da Computação.

Engenharia da Computação
Universidade Federal do Maranhão

Orientador: Prof. Dr. Haroldo Gomes Barroso Filho

São Luís - MA

2025

Leonardo Lima Castelo Branco

Classificação de níveis neurodegenerativos utilizando *deep learning*

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia da Computação da Universidade Federal do Maranhão como requisito parcial para a obtenção do grau de Bacharel em Engenharia da Computação.

Trabalho de conclusão de curso. São Luís - MA, 18 de Fevereiro de 2025:

**Prof. Dr. Haroldo Gomes Barroso
Filho**
Orientador
Universidade Federal do Maranhão

São Luís - MA
2025

Aos nossos pais.

Agradecimentos

Primeiramente, gostaria de expressar minha sincera gratidão ao Prof. Dr. Haroldo Gomes Barroso Filho, meu orientador, que sempre se mostrou extremamente solícito e acolheu a ideia deste projeto desde o início. Sem seus direcionamentos, não teria conseguido realizar este trabalho da maneira como foi executado. Da mesma forma, gostaria de manifestar minha gratidão à Universidade Federal do Maranhão (UFMA) por me proporcionar o ambiente acadêmico necessário para o desenvolvimento do conhecimento. Sou profundamente gratos à instituição e a cada um de seus colaboradores.

Além disso, expresso minha sincera gratidão aos meus pais, meus maiores incentivadores, que sempre estiveram ao meu lado e se dedicaram incansavelmente para me proporcionar uma educação de qualidade e todo o conhecimento adquirido ao longo da minha trajetória acadêmica.

"Dream big, be bold, stay curious"

Resumo

As doenças neurodegenerativas, como o Alzheimer, representam um grande desafio para a medicina moderna devido a sua progressão silenciosa e ao impacto significativo na qualidade de vida dos pacientes e seus familiares. Tradicionalmente, o diagnóstico é realizado por meio de exames clínicos, testes cognitivos e análises de imagens médicas, que muitas vezes envolvem métodos manuais e subjetivos. No entanto, com os avanços da tecnologia, o uso de inteligência artificial e do deep learning tem se mostrado promissor para tornar o processo mais preciso e eficiente.

Este trabalho utiliza redes neurais convolucionais (CNNs) e análise de exames de ressonância magnética (IRM) para a classificação de diferentes níveis neurodegenerativos em pacientes com Alzheimer. Além disso, técnicas de processamento de imagens, como a detecção de bordas, são exploradas para aprimorar a segmentação de regiões cerebrais afetadas. O objetivo é desenvolver um modelo capaz de identificar padrões sutis na estrutura cerebral, auxiliando no diagnóstico precoce da doença.

Com essa abordagem, espera-se contribuir para a criação de ferramentas computacionais que possam apoiar profissionais da saúde no diagnóstico do Alzheimer, tornando-o mais confiável. Dessa forma, este estudo busca aliar tecnologia à área médica, oferecendo soluções que impactem positivamente na vida dos pacientes.

Palavras-chave: Alzheimer, Deep learning, Rede neural.

Abstract

Neurodegenerative diseases, such as Alzheimer's, represent a major challenge for medicine due to their silent progression and significant impact on the quality of life of patients and their families. Traditionally, diagnosis is made through clinical examinations, cognitive tests and medical image analyses, which often involve manual and subjective methods. However, with advances in technology and deep learning, the use of artificial intelligence has shown promise in making this process more accurate and efficient.

This work uses convolutional neural networks (CNNs) to analyze magnetic resonance imaging (MRI) scans to classify different neurodegenerative levels in Alzheimer's patients. Furthermore, image processing techniques such as edge detection are explored to improve the segmentation of affected brain regions. The objective is to develop a model capable of identifying subtle patterns in the brain structure, helping to diagnose the disease early.

With this approach, we hope to contribute to the creation of computational tools that can support healthcare professionals in diagnosing Alzheimer's, making it more reliable. Therefore, this study seeks to combine technology with the medical field, offering solutions that positively impact patients' lives.

Keywords: Alzheimer's, Deep Learning, Neural Network.

Lista de ilustrações

Figura 1 – Imagens alzheimer MRI Disease. Fonte: (FALAH.G.SALIEH, 2023).	23
Figura 2 – Arquitetura CNN. Fonte: Autor.	24
Figura 3 – Imagens alzheimer MRI Disease Filtro Sobel. Fonte: Autor.	25
Figura 4 – Função filtro sobel. Fonte: Autor.	26
Figura 5 – Imagens alzheimer MRI Disease Filtro Canny. Fonte: (??).	27
Figura 6 – Função filtro canny. Fonte: Autor.	27
Figura 7 – Imagens alzheimer MRI Disease Filtro Laplaciano. Fonte: Autor.	28
Figura 8 – Função filtro laplaciano. Fonte: Autor.	28
Figura 9 – Matriz Confusão Modelo sem Filtos. Fonte: Autor.	33
Figura 10 – Matriz Confusão Filtro Sobel. Fonte: Autor.	34
Figura 11 – Matriz Confusão Filtro Canny. Fonte: Autor.	35
Figura 12 – Matriz Confusão Filtro Laplaciano. Fonte: Autor.	36

Sumário

1	INTRODUÇÃO	11
1.1	Objetivos e Justificativa	12
1.2	Organização do trabalho	13
2	FUNDAMENTAÇÃO TEÓRICA	14
2.1	Trabalhos Correlatos	14
2.2	Patologias neurodegenerativas	16
2.2.1	Alzhemeir	16
2.3	Inteligencia Artificial	17
2.3.1	Deep Learning	17
2.3.1.1	Convolução	18
2.3.1.2	Pooling	18
2.3.2	Data Augmentation	19
2.3.2.1	Filtro Sobel	19
2.3.2.2	Filtro Canny	20
2.3.2.3	Filtro Laplaciano	21
3	METODOLOGIA	22
3.1	DataSet	22
3.2	Rede Neural Convolucional	23
3.3	Implementação Data Augmentation	25
3.3.1	Filtro Sobel	25
3.3.2	Filtro Canny	26
3.3.3	Filtro Laplaciano	27
4	METRICAS DE AVALIAÇÃO	29
4.1	Acurácia	29
4.2	Matriz de Confusão	29
4.3	Métricas de Classificação: Precisão, Revocação e F1-score	30
4.3.1	Precisão (Precision)	30
4.3.2	Revocação (Recall)	31
4.3.3	F1-score	32
5	RESULTADOS	33
6	CONCLUSÃO	37

REFERÊNCIAS 38

1 Introdução

As doenças neurodegenerativas, como o Alzheimer, representam um dos desafios mais significativos da medicina moderna devido a sua progressão silenciosa e ao impacto devastador na qualidade de vida dos pacientes e familiares. Tradicionalmente, a detecção dessas patologias era realizada por meio de exames clínicos e testes cognitivos, os quais dependiam fortemente da experiência do profissional de saúde e da percepção subjetiva de mudanças comportamentais. Com a evolução dos métodos de diagnóstico, exames de imagem, como a Ressonância Magnética (IRM) e a Tomografia por Emissão de Pósitrons (PET), desempenham um papel fundamental na identificação da doença, permitindo detectar alterações estruturais e metabólicas no cérebro antes do surgimento dos sintomas clínicos. Diante disso, a análise automatizada dessas imagens se torna essencial para reduzir a subjetividade e aumentar a precisão do diagnóstico ([JACK; HOLTZMAN, 2013](#)).

Com o avanço da ciência e engenharia da computação e o desenvolvimento de novas técnicas de análise de imagens, a utilização de algoritmos de aprendizado de máquina tornou-se uma alternativa viável para a classificação de níveis neurodegenerativos. Métodos tradicionais de aprendizado de máquina, como SVM (*Support Vector Machines*) e *Random Forest*, foram aplicados na tentativa de automatizar a detecção de padrões em exames de IRM. No entanto, esses métodos dependiam fortemente da seleção manual de características, tornando o processo de diagnóstico ainda limitado pela expertise humana.

Nos últimos anos, o deep learning revolucionou a forma como problemas complexos de classificação e reconhecimento de padrões são tratados. Redes neurais convolucionais (CNNs) mostraram-se altamente eficazes na análise de imagens médicas, permitindo a extração automática de características relevantes sem necessidade de intervenção humana. Essas redes são capazes de identificar padrões sutis em exames de IRM, muitas vezes imperceptíveis ao olho humano, assim, contribuindo para um diagnóstico mais preciso e precoce de doenças, como o Alzheimer.

Ademais, técnicas de processamento de imagens, como a detecção de bordas, são empregadas em conjunto com algoritmos de deep learning para melhorar a segmentação de regiões cerebrais afetadas. A detecção de bordas permite realçar contornos e estruturas específicas dentro das imagens de IRM, facilitando a identificação de áreas de atrofia e outras alterações neurodegenerativas. Quando integradas a redes neurais profundas, essas técnicas potencializam a precisão dos diagnósticos e reduzem a necessidade de segmentação manual, tornando o processo mais eficiente e confiável.

1.1 Objetivos e Justificativa

O presente trabalho tem como objetivo principal investigar e desenvolver modelos de aprendizado profundo, com ênfase em redes neurais convolucionais (CNNs), para a análise automatizada de exames de imagem na detecção de níveis da Doença de Alzheimer. Além disso, busca-se avaliar a eficácia da integração entre técnicas de processamento de imagens, como a detecção de bordas, e algoritmos de deep learning, visando aprimorar a segmentação e identificação de padrões neurodegenerativos. Por meio da implementação e experimentação, primeiramente de uma arquitetura CNN sem *data augmentation* (DA), e depois com DA, para então comparar a precisão dos modelos desenvolvidos e avaliar qual teve um resultado superior.

A justificativa para este estudo fundamenta-se na necessidade crescente de métodos mais rápidos, precisos e automatizados para o diagnóstico da Doença de Alzheimer. O diagnóstico convencional ainda apresenta desafios significativos, como a dependência da expertise médica e a subjetividade na interpretação dos exames, o que pode levar a variações na detecção da doença. O uso de redes neurais profundas possibilita a extração de características complexas diretamente das imagens, reduzindo a necessidade de segmentação manual e aumentando a reprodutibilidade das análises. Dessa forma, um sistema automatizado baseado em aprendizado profundo pode otimizar o processo diagnóstico, permitindo intervenções médicas mais precoces e eficazes.

Além do impacto na medicina diagnóstica, o desenvolvimento de técnicas mais avançadas para a análise de imagens médicas também contribui para o avanço da ciência computacional, especialmente no campo da visão computacional aplicada à saúde. O aprimoramento de modelos baseados em CNNs pode ser útil para outras doenças neurodegenerativas e para diferentes tipos de exames médicos. Assim, este estudo não apenas busca fornecer um modelo mais eficiente para a detecção do Alzheimer, mas também pretende servir de referência para futuras pesquisas que explorem o potencial do aprendizado profundo em aplicações biomédicas.

1.2 Organização do trabalho

Este trabalho está estruturado da seguinte maneira:

- Capítulo 2 revisa a literatura e trabalhos relacionados sobre os princípios e conceitos acerca de deep learning, com ênfase em redes neurais convolucionais e dos filtros aplicados, sobel, canny, laplaciano;
- Capítulo 3 descreve a abordagem metodológica utilizada no estudo;
- Capítulo 4 apresenta os resultados obtidos a partir do modelo de deep learning e da aplicação dos filtros;
- Capítulo 5 apresenta as conclusões obtidas a partir dos resultados obtidos;
- Capítulo 6 apresenta as considerações finais, uma síntese dos principais pontos abordados no trabalho e os próximos passos.

2 Fundamentação Teórica

Este capítulo apresenta o referencial teórico utilizado como base para o desenvolvimento e execução do trabalho proposto. Nele, serão abordados os conceitos essenciais que proporcionarão uma compreensão aprofundada do estudo de caso.

A revisão bibliográfica tem como objetivo fornecer uma fundamentação sólida, embasada em estudos e teorias existentes, para fundamentar as decisões tomadas durante o desenvolvimento do trabalho, permitindo ao pesquisador conhecer o que já se estudou sobre o assunto (SOUSA; OLIVEIRA; ALVES, 2021).

2.1 Trabalhos Correlatos

A detecção e classificação da doença de Alzheimer a partir de imagens de ressonância magnética (IRM) têm sido muito estudada na literatura, com várias abordagens que variam desde *machine learning* (ML) tradicional até redes neurais profundas. Nesse sentido, foi feita uma análise de cinco trabalhos que abordam diferentes metodologias para o diagnóstico da doença, destacando suas contribuições, arquiteturas utilizadas e desempenho obtido.

No estudo conduzido por Ishibe (ISHIBE, 2022), foram utilizadas redes neurais convolucionais (CNNs) rasas para classificar imagens de IRM em quatro categorias: *Non Demented*, *VeryMild Demented*, *Mild Demented* e *Moderate Demented*. A abordagem consistiu em treinar redes neurais do zero, sem a necessidade de extração manual de características, permitindo que o modelo aprendesse automaticamente padrões relevantes nas imagens. O autor comparou o desempenho das CNNs com um classificador *Support Vector Machine* (SVM) e observou que a CNN superou a linha de base, apresentando melhor acurácia na predição dos estágios da doença.

Pesquisadores da Universidade Federal do Rio Grande do Norte (UFRN, 2022) exploraram o uso do SVM com kernel polinomial na classificação binária entre pacientes com Alzheimer e controles saudáveis. Além disso, técnicas de processamento digital de imagens foram empregadas para melhorar a segmentação e realce das regiões cerebrais. O modelo proposto atingiu uma acurácia de 85,71%, destacando-se como uma solução viável para auxiliar diagnósticos clínicos.

O trabalho de Matos (MATOS, 2012) analisou imagens ponderadas em difusão utilizando mapas de coeficientes de difusão aparente (ADC) para avaliar alterações estruturais cerebrais associadas ao Alzheimer. A abordagem se diferenciou por focar em propriedades físicas da difusão de moléculas de água no tecido cerebral, permitindo uma análise mais detalhada da degeneração neuronal. O estudo demonstrou que essa técnica pode ser

utilizada como um biomarcador eficiente para identificar estágios iniciais da doença.

O estudo realizado por Correia (CORREIA, 2023) investigou a aplicação de modelos de *machine learning* para a classificação de diferentes estágios da doença de Alzheimer. As imagens de IRM foram processadas e utilizadas para treinar modelos supervisionados, permitindo a categorização em quatro grupos distintos: *Non Demented*, *VeryMild Demented*, *Mild Demented* e *Moderate Demented*. Embora o autor não tenha especificado valores exatos de acurácia, os resultados indicaram que as técnicas de ML foram eficazes na predição dos estágios da doença.

No trabalho de Seraj (SERAJ M., 2019), foram analisados parâmetros cerebrais instantâneos derivados de imagens de IRM para distinguir pacientes com Alzheimer, comprometimento cognitivo leve (MCI) e indivíduos saudáveis. As características de fase e envelope dos sinais cerebrais foram extraídas e utilizadas para treinar um classificador K-NN, que obteve uma acurácia de 80,1%, demonstrando que essa abordagem pode ser útil na detecção da doença.

Diante disso, cada um dos estudos analisados apresenta abordagens distintas para a classificação da doença de Alzheimer. Enquanto alguns utilizam técnicas tradicionais, como SVM e análise de difusão, outros apostam em arquiteturas mais modernas, como redes neurais convolucionais e aprendizado profundo.

As CNNs, conforme apresentado por (ISHIBE, 2022), demonstraram um potencial significativo por aprender automaticamente padrões relevantes sem necessidade de intervenção humana na extração de características. Por outro lado, a abordagem de (SERAJ M., 2019) com IRM e K-NN mostrou-se eficaz na análise de padrões de atividade cerebral, embora com uma acurácia inferior às técnicas baseadas em *deep learning*.

O estudo da (UFRN, 2022) destacou-se pelo uso do SVM com kernel polinomial, conseguindo um bom desempenho na classificação binária. Já o trabalho de (MATOS, 2012) trouxe uma abordagem diferenciada ao focar em imagens ponderadas em difusão, fornecendo informações complementares sobre a estrutura cerebral.

Por fim, a pesquisa de (CORREIA, 2023) explorou o *machine learning* sem especificar valores exatos de acurácia, mas reafirmando a relevância dessas técnicas no auxílio ao diagnóstico da doença. A tabela a seguir resume os principais aspectos de cada estudo:

Tabela 1 – Comparação dos Trabalhos Relacionados

Autor(es)	Método	Resultado
Ishibe (2022)	CNNs	92,3%
UFRN (2022)	SVM	85,71%
Matos (2012)	ADC Maps	Deteção de atrofia
Correia (2023)	ML em IRM	>88%
Seraj et al. (2019)	IRM + K-NN	80,1%

2.2 Patologias neurodegenerativas

As doenças neurodegenerativas são um grupo heterogêneo de distúrbios caracterizados pela degeneração progressiva e irreversível de neurônios, levando à disfunção e morte celular no sistema nervoso central. Essas doenças afetam diferentes áreas do cérebro e da medula espinhal, resultando em comprometimentos motores, cognitivos e comportamentais. Entre as mais comuns estão a Doença de Alzheimer, Doença de Parkinson, Esclerose Lateral Amiotrófica (ELA) e Doença de Huntington. Os principais mecanismos envolvidos incluem o acúmulo de proteínas mal dobradas, estresse oxidativo, neuroinflamação e disfunções mitocondriais, que contribuem para a perda neuronal progressiva (PRZEDBORSKI et al., 2003).

Essas patologias causam impactos significativos na vida dos pacientes e familiares, uma vez que afetam tanto as capacidades motoras quanto as cognitivas dos portadores. Atualmente, essas enfermidades ainda representam um grande desafio para a medicina moderna, devido a sua progressão irreversível e à ausência de tratamentos definitivos.

2.2.1 Alzhemeir

Dentre as patologias neurodegenerativas, a Doença de Alzheimer (DA) é uma enfermidade progressiva caracterizada pelo declínio cognitivo e perda de memória, resultantes da morte neuronal e atrofia cerebral. A fisiopatologia da doença está associada ao acúmulo extracelular de placas de beta-amiloide e à hiperfosforilação da proteína tau, levando à formação de emaranhados neurofibrilares. Esses processos desencadeiam neuroinflamação, disfunção sináptica e morte neuronal, comprometendo progressivamente funções como memória, linguagem e orientação espacial. Embora sua etiologia não seja completamente compreendida, fatores genéticos, inflamatórios e ambientais estão implicados no desenvolvimento da doença (QUERFURTH; LAFERLA, 2010). A Doença de Alzheimer é a forma mais comum de demência neurodegenerativa em pessoas idosas, sendo responsável por mais da metade dos casos de demência nessa população, gerando um grande abalo social e econômico para as famílias envolvidas e para a sociedade como um todo. Atualmente o tratamento dessa patologia é feito através de terapia farmacológica visando amenizar os sintomas e retardar alguns danos gerados pela doença. (REIS; MARQUES; MARQUES, 2022)

2.3 Inteligencia Artificial

A Inteligência Artificial (IA) é um campo da ciência da computação que busca desenvolver sistemas capazes de realizar tarefas que tradicionalmente requerem inteligência humana, como reconhecimento de padrões, tomada de decisão e processamento de linguagem natural (RUSSELL; NORVIG, 2016). Desde sua criação, a IA evoluiu significativamente, abrangendo desde sistemas baseados em regras até abordagens mais avançadas, como as redes neurais profundas. Seu impacto pode ser observado em diversas áreas, como saúde, finanças, segurança e automação industrial.

A IA pode ser classificada em dois principais tipos: IA fraca e IA forte. A IA fraca refere-se a sistemas especializados em resolver tarefas específicas, como assistentes virtuais e sistemas de recomendação. Já a IA forte, ainda um objetivo teórico, se refere a sistemas com capacidades cognitivas similares às humanas, capazes de aprender e raciocinar de maneira generalizada (GOODFELLOW, 2016).

Os avanços recentes em IA foram impulsionados principalmente pelo aumento da capacidade computacional, disponibilidade de grandes volumes de dados e desenvolvimento de algoritmos mais eficientes. Entre as principais aplicações da IA, destacam-se a visão computacional, utilizada em reconhecimento facial e diagnóstico médico, e o processamento de linguagem natural (PLN), empregado em chatbots e tradução automática. Além disso, a IA tem sido amplamente utilizada em sistemas autônomos, como veículos inteligentes e robôs industriais.

Um dos grandes marcos da IA moderna foi o avanço das redes neurais artificiais (RNA), que são modelos matemáticos inspirados no funcionamento do cérebro humano. Dentro desse contexto, um dos pilares fundamentais para o avanço da Inteligência Artificial é o *machine learning* (ML), um subcampo da IA que permite aos sistemas aprender e aprimorar seu desempenho automaticamente a partir de dados, sem a necessidade de uma programação explícita. O ML revolucionou a forma como modelos computacionais são desenvolvidos e aplicados, tornando-se a base de inúmeras inovações tecnológicas, uma abordagem que se destacou foi o aprendizado profundo (*deep learning*), que utiliza múltiplas camadas de neurônios artificiais para extrair padrões complexos de grandes quantidades de dados (LECUN; BENGIO; HINTON, 2015).

2.3.1 Deep Learning

O *deep learning* é um subcampo do *machine learning* que utiliza redes neurais artificiais com múltiplas camadas para modelar e extrair padrões complexos de dados. Essa abordagem se mostrou altamente eficaz em diversas aplicações, como reconhecimento de imagens, processamento de linguagem natural e tomada de decisões autônomas (LECUN; BENGIO; HINTON, 2015).

Diferentemente dos métodos tradicionais de ML que frequentemente exigem extração manual de características, o *deep learning* é capaz de aprender representações hierárquicas automaticamente a partir dos dados brutos. A estrutura básica dessas redes é composta por neurônios artificiais, organizados em camadas de entrada, ocultas e saída. Cada camada aplica transformações matemáticas aos dados, ajustando seus pesos por meio do algoritmo de retropropagação do erro (*backpropagation*), que utiliza o gradiente descendente para minimizar a função de perda (GOODFELLOW, 2016).

2.3.1.1 Convolução

A convolução é uma operação matemática fundamental no funcionamento das Redes Neurais Convolucionais (CNNs), amplamente utilizadas no processamento de imagens. Esse método permite que a rede extraia características espaciais de uma imagem, detectando padrões como bordas, texturas e formas em diferentes escalas.

Matematicamente, a convolução entre um filtro (ou kernel) K e uma entrada X é definida como:

$$S(i, j) = \sum_m \sum_n X(i + m, j + n) \cdot K(m, n) \quad (2.1)$$

Onde $S(i, j)$ representa a matriz resultante após a aplicação do filtro, $X(i + m, j + n)$ é um pixel de entrada de imagem e $K(m, n)$ é um coeficiente do kernel. Essa operação desliza o kernel sobre a imagem, gerando um mapa de características que enfatiza padrões específicos. Diferentes filtros podem ser treinados para detectar bordas horizontais, verticais, curvas e outras estruturas relevantes na imagem (GU et al., 2018).

2.3.1.2 Pooling

Após a convolução, as redes neurais convolucionais frequentemente utilizam uma operação chamada pooling, que reduz a dimensionalidade do mapa de características, diminuindo a carga computacional e tornando a rede mais robusta a variações na entrada. Os dois tipos principais são:

Max Pooling: seleciona o maior valor dentro de uma janela deslizante. Matematicamente:

$$P(i, j) = \max_{(m, n) \in W} S(i + m, j + n) \quad (2.2)$$

Onde W representa a janela de pooling.

Average Pooling: calcula a média dos valores dentro da janela:

$$P(i, j) = \frac{1}{|W|} \sum_{(m, n) \in W} S(i + m, j + n) \quad (2.3)$$

Assim, o pooling contribui para a invariância espacial, garantindo que pequenas translações na imagem original não afetem drasticamente a saída da rede. Esse processo melhora a generalização do modelo e reduz a probabilidade de *overfitting* (DUMOULIN; VISIN, 2016).

2.3.2 Data Augmentation

O *data augmentation* (aumento de dados) é uma técnica amplamente utilizada no treinamento de modelos de *deep learning*, especialmente em tarefas de visão computacional. Seu principal objetivo é expandir artificialmente o conjunto de dados de treinamento, aplicando transformações nas imagens originais, como rotações, espelhamentos, mudanças de brilho e aplicação de filtros. Essa abordagem melhora a generalização do modelo e reduz o risco de *overfitting*, garantindo que a rede neural não memorize padrões específicos do conjunto de treinamento, mas sim aprenda representações mais robustas (SHORTEN; KHOSHGOFTAAR, 2019). Diante disso, as técnicas baseadas em filtros de realce de bordas, como os filtros Sobel, Canny e Laplaciano, podem ser utilizadas para enfatizar características específicas das imagens. Assim, esses filtros são utilizados no processamento de imagens, pois permitem identificar transições abruptas de intensidade, destacando contornos e detalhes relevantes. São frequentemente usados em *data augmentation* para melhorar a capacidade das redes neurais de capturar padrões estruturais.

2.3.2.1 Filtro Sobel

O filtro Sobel é um operador diferencial que calcula a aproximação do gradiente da intensidade da imagem. Ele é muito utilizado para detecção de bordas, pois realça variações locais de intensidade ao longo das direções horizontal e vertical (SOBEL, 1990). Matematicamente, o gradiente de uma imagem $I(x,y)$ é aproximado por duas convoluções separadas:

$$G_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} * I(x, y) \quad (2.4)$$

$$G_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} * I(x, y) \quad (2.5)$$

Onde G_x e G_y representam os gradientes nas direções horizontal e vertical, respectivamente. A magnitude do gradiente pode ser calculada como:

$$G = \sqrt{G_x^2 + G_y^2} \quad (2.6)$$

E a direção da borda é dada por:

$$\theta = \tan^{-1} \left(\frac{G_y}{G_x} \right) \quad (2.7)$$

2.3.2.2 Filtro Canny

O filtro Canny é um método mais avançado para detecção de bordas, baseado em várias etapas de processamento. Ele busca identificar bordas de forma otimizada, o filtro de Canny é um filtro de convolução que usa a primeira derivada. Ele suaviza o ruído e localiza bordas, combinando um operador diferencial com um filtro Gaussiano. Minimizando falsas detecções e assegurando a conectividade dos contornos. Seu funcionamento envolve os seguintes passos (CANNY, 1986):

1. Primeiramente, é necessário reduzir o ruído presente na imagem. Para isso, aplica-se um filtro Gaussiano, que suaviza a imagem, eliminando pequenas variações de intensidade que poderiam ser interpretadas erroneamente como bordas. A suavização é feita por meio da convolução da imagem original $I(x,y)$ com um kernel Gaussiano $G(x,y)$, definido pela seguinte equação:

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (2.8)$$

Onde, (x,y) são as coordenadas do pixel na imagem e σ é o desvio padrão do filtro Gaussiano.

2. Após a suavização, é necessário calcular as derivadas parciais da imagem para identificar variações na intensidade de pixels. Para isso, utilizamos os operadores de Sobel, que aproximam a derivada da imagem nas direções horizontal (G_x) e vertical(G_y):

$$G_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} * I(x, y) \quad (2.9)$$

$$G_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} * I(x, y) \quad (2.10)$$

Onde $*$ representa a operação de convolução. O gradiente resultante é obtido pela magnitude G :

$$G = \sqrt{G_x^2 + G_y^2} \quad (2.11)$$

E a direção da borda é calculada como:

$$\theta = \tan^{-1} \left(\frac{G_y}{G_x} \right) \quad (2.12)$$

3. Nessa etapa, o objetivo é remover pixels que não representam bordas fortes. Desse modo, percorremos a imagem e comparamos cada pixel com seus vizinhos na direção do gradiente θ . Um pixel (x, y) será mantido como borda apenas se sua magnitude $G(x, y)$ for maior do que a de seus vizinhos ao longo da direção do gradiente.
4. A última etapa do filtro de Canny consiste em eliminar bordas fracas e manter apenas as mais relevantes. Portanto, são definidos dois limiares:
 - **Limiar alto** (T_h): pixels com intensidade superior a T_h são mantidos como bordas definitivas.
 - **Limiar baixo** (T_l): pixels com intensidade entre T_l e T_h são mantidos apenas se estiverem conectados a pixels acima do limiar alto.

O Canny é considerado um dos melhores algoritmos para detecção de bordas devido a sua robustez contra ruídos e à precisão na identificação dos contornos (DERICHE, 1987).

2.3.2.3 Filtro Laplaciano

O filtro Laplaciano é um operador diferencial de segunda ordem que realça regiões onde há mudanças abruptas de intensidade. Ele utiliza a segunda derivada da função intensidade, sendo altamente sensível à variações bruscas na imagem (MARR; HILDRETH, 1980). A formulação matemática do Laplaciano é dada por:

$$\nabla^2 I = \frac{\partial^2 I}{\partial x^2} + \frac{\partial^2 I}{\partial y^2} \quad (2.13)$$

A convolução da imagem com a máscara Laplaciana pode ser feita utilizando o seguinte kernel:

$$L = \begin{bmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{bmatrix} \quad (2.14)$$

Esse filtro é útil para realçar bordas e detalhes, mas, devido a sua sensibilidade ao ruído, muitas vezes é combinado com uma suavização Gaussiana (LoG - Laplacian of Gaussian) para melhorar a precisão na detecção de contornos.

3 Metodologia

Neste capítulo, será apresentada a metodologia utilizada para a realização deste trabalho, considerando que o objetivo é criar um modelo de deep learning capaz de identificar os níveis da doença de Alzheimer a partir de exames de imagem, em específico ressonância magnética.

A metodologia adotada nesse estudo baseia-se na revisão da literatura existente sobre o uso de aprendizado profundo na classificação de imagens de ressonância magnética, bem como em artigos e trabalhos que discutem abordagens computacionais para diagnósticos médicos, além disso, foi realizada a experimentação prática utilizando o conjunto de dados Alzheimer MRI Disease Classification, no qual modelos de *deep learning* foram treinados e avaliados para a classificação dos diferentes estágios da doença. A análise dos resultados será conduzida de forma quantitativa, considerando métricas de desempenho como acurácia e matriz de confusão.

3.1 DataSet

Para o desenvolvimento deste trabalho, utilizamos o conjunto de dados Alzheimer MRI Disease Classification (figura 1), um recurso valioso para pesquisas na área de saúde e aplicações em medicina. Esse dataset tem como principal objetivo a classificação do Alzheimer a partir de imagens de ressonância magnética (IRM) do cérebro, este possibilita o desenvolvimento de modelos de inteligência artificial capazes de auxiliar no diagnóstico precoce do Alzheimer. A organização estruturada das imagens permite treinar redes neurais convolucionais (CNNs) e outros algoritmos de aprendizado profundo (*Deep Learning*) para reconhecer padrões característicos da doença, sendo dividido em quatro categorias conforme seu estágio:

- *Mild Demented*(Leve): indivíduos com sinais iniciais de demência;
- *Moderate Demented* (Moderada): pacientes com um nível mais avançado da doença;
- *non demented* (Sem Demência): indivíduos saudáveis, sem sinais da doença;
- *Very Mild Demented* (Muito Leve): indivíduos com sintomas muito leves da doença;

A base de dados está organizada em dois conjuntos principais: treinamento (*train*) e teste (*test*), permitindo avaliar o desempenho dos modelos de aprendizado de máquina. Na tabela a baixo é possível observar a estrutura do dataset:




Figura 1 – Imagens alzheimer MRI Disease. Fonte: ([FALAH.G.SALIEH, 2023](#)).

Tabela 2 – Estrutura do dataset Alzheimer MRI Disease Classification

Conjunto	Número de Exemplos	Tamanho (bytes)
Treinamento (<i>train</i>)	5.120	22.560.791,2
Teste (<i>test</i>)	1.280	5.637.447,08
Total	6.400	28.198.238,28

O conjunto de treinamento contém 5.120 imagens, enquanto o conjunto de teste possui 1.280 imagens, garantindo uma divisão adequada para treinar e validar o modelo.

Além disso, o tamanho total do dataset para download é de 28.289.848 bytes, sendo que o tamanho efetivo após o processamento é de 28.198.238,28 bytes.

3.2 Rede Neural Convolucional

A arquitetura utilizada para a classificação das imagens é baseada em uma Rede Neural Convolucional (CNN) (figura 2):




Figura 2 – Arquitetura CNN. Fonte: *Autor*.

Esse modelo é amplamente empregado para tarefas de visão computacional devido a sua capacidade de extrair padrões espaciais relevantes. O modelo foi implementado utilizando a biblioteca TensorFlow/Keras. A rede neural convolucional implementada segue uma estrutura sequencial composta por múltiplas camadas convolucionais, de normalização e totalmente conectadas. A arquitetura pode ser descrita a seguir:

- Camada de Convolução (Conv2D): a primeira camada convolucional contém 32 filtros de tamanho 3x3, ativação ReLU e preenchimento "same" para preservar a dimensão da imagem.
- Camada de Pooling (MaxPooling2D): uma camada de pooling 2x2 é aplicada para reduzir dimensionalidade e melhorar a eficiência computacional;
- Camada de Normalização (BatchNormalization): normaliza os valores da camada anterior para estabilizar o treinamento;
- Segunda Camada de Convolução (Conv2D): com 64 filtros de tamanho 3x3, ativação ReLU e preenchimento "same", essa camada aprofunda a extração de características;
- Camada de Pooling e Normalização: similar à anterior, reduz a dimensionalidade e mantém a estabilidade do modelo;
- Camada Flatten: converte os mapas de características em um vetor unidimensional;
- Camada Densa (Fully Connected): uma camada densa de 128 neurônios com ativação ReLU;

- Camada de Saída (Softmax): a camada final contém 4 neurônios correspondentes às classes do problema, aplicando a ativação softmax para gerar probabilidades.

O treinamento desse modelo utilizou o otimizador Adam com uma taxa de aprendizado de 0.001 e função de perda `sparse_categorical_crossentropy`. O treinamento foi realizado por meio de 100 épocas com parada antecipada caso a acurácia de validação não apresentasse melhorias por 5 épocas consecutivas. Para evitar overfitting, o conjunto de dados foi dividido em treino (80%) e validação (20%).

3.3 Implementação Data Augmentation

Nesse projeto foram utilizados filtros de realce de bordas a fim de observar quais resultados trariam para o modelo, sua implementação utilizava as imagens obtidas a partir de um conjunto de dados armazenado em arquivos do tipo Parquet. Esses arquivos continham as imagens no formato de dicionários serializados em bytes. Para recuperar as imagens, os bytes foram convertidos em matrizes NumPy utilizando a biblioteca OpenCV. Em seguida as imagens passavam pelo filtro, destacando bordas e contornos antes do treinamento da rede neural.

3.3.1 Filtro Sobel

O Filtro de Sobel é aplicado a todas as imagens do conjunto (figura 3) de dados antes de serem usadas para treinar a CNN. Isso foi feito por meio da função abaixo:




Figura 3 – Imagens alzheimer MRI Disease Filtro Sobel. Fonte: *Autor*.

Onde sua implementação segue os seguintes passos (figura 4):

1. Verificação e Ajuste da Imagem: a imagem pode estar em formato (128,128,1), então o código remove o canal extra, se necessário.;
2. Aplicação dos Filtros de Sobel: onde a função `cv2.Sobel` calcula o gradiente na direção horizontal (X) e na direção vertical (Y);
3. Cálculo da Magnitude: a função `cv2.magnitude`, combina os gradientes horizontal e vertical para obter a intensidade das bordas;
4. Normalização: a função `cv2.normalize`, ajusta os valores da imagem para ficar entre 0 e 255, garantindo que a intensidade seja compatível com a entrada da CNN.

```
# Function to apply the Sobel filter
def apply_sobel_filter(img):
    if img.ndim == 3 and img.shape[-1] == 1: # Check if image has a channel dimension
        img = img.squeeze() # Remove the channel dimension

    # Apply Sobel filter for x and y gradients
    sobelx = cv2.Sobel(img, cv2.CV_64F, 1, 0, ksize=3) # Horizontal gradient
    sobely = cv2.Sobel(img, cv2.CV_64F, 0, 1, ksize=3) # Vertical gradient

    # Combine the gradients
    sobel_combined = cv2.magnitude(sobelx, sobely)

    # Normalize to the range [0, 255]
    sobel_combined = cv2.normalize(sobel_combined, None, 0, 255, cv2.NORM_MINMAX)

    return sobel_combined.astype(np.uint8)
```

Figura 4 – Função filtro sobel. Fonte: *Autor*.

3.3.2 Filtro Canny

Para a implementação do filtro canny cada imagem (figura 5) foi carregada em escala de cinza e submetida a ele.




Figura 5 – Imagens alzheimer MRI Disease Filtro Canny. Fonte: (??).

No código (figura 6), o filtro foi aplicado com limiares de 100 e 200, utilizando a função `cv2.Canny`. Esse processo permitiu a extração das principais características estruturais das imagens, facilitando a identificação de padrões relevantes para a classificação.

```
# Apply Canny filter to an image
def apply_canny_filter(img):
    return cv2.Canny(img, 100, 200).astype(np.float32)
```

Figura 6 – Função filtro canny. Fonte: Autor.

3.3.3 Filtro Laplaciano

Para a aplicação do filtro laplaciano (figura 7), as imagens foram carregadas em uma escala cinza e submetidas ao filtro




Figura 7 – Imagens alzheimer MRI Disease Filtro Laplaciano. Fonte: *Autor*.

Foi utilizado a função `cv2.Laplacian` (figura 8).

```
# Apply Laplacian filter to an image
def apply_laplacian_filter(img):
    return cv2.Laplacian(img, cv2.CV_64F).astype(np.float32)
```

Figura 8 – Função filtro laplaciano. Fonte: *Autor*.

4 Métricas de Avaliação

A avaliação de modelos de classificação em aprendizado de máquina é fundamental para medir seu desempenho e eficácia. As métricas de avaliação empregadas neste trabalho permitiram uma análise detalhada do desempenho da CNN implementada. A acurácia forneceu uma visão geral da performance do modelo, enquanto a matriz de confusão revelou padrões específicos de erro. O relatório de classificação, por sua vez, garantiu uma avaliação mais detalhada da qualidade das previsões do modelo.

4.1 Acurácia

A acurácia é uma das métricas mais simples e intuitivas para avaliação de classificadores. Ela mede a proporção de previsões corretas em relação ao total de exemplos avaliados, sendo definida matematicamente como:

$$\text{Acurácia} = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.1)$$

Onde:

- **TP (True Positives)**: casos positivos corretamente classificados;
- **TN (True Negatives)**: casos negativos corretamente classificados;
- **FP (False Positives)**: casos negativos incorretamente classificados como positivos;
- **FN (False Negatives)**: casos positivos incorretamente classificados como negativos.

A acurácia é útil quando o conjunto de dados está balanceado, mas pode ser enganosa quando há um desequilíbrio significativo entre as classes.

4.2 Matriz de Confusão

A Matriz de Confusão é uma representação tabular do desempenho do modelo, indicando a distribuição das previsões entre as classes verdadeiras e preditas. Para um problema de classificação com quatro classes (como no presente trabalho), a matriz assume a seguinte forma:

	Predito: C1	Predito: C2	Predito: C3	Predito: C4
Real: C1	TP ₁	FP ₁₂	FP ₁₃	FP ₁₄
Real: C2	FP ₂₁	TP ₂	FP ₂₃	FP ₂₄
Real: C3	FP ₃₁	FP ₃₂	TP ₃	FP ₃₄
Real: C4	FP ₄₁	FP ₄₂	FP ₄₃	TP ₄

Tabela 3 – Exemplo de Matriz de Confusão para um problema de quatro classes.

A matriz de confusão apresenta os valores das previsões do modelo em relação às classes reais. Cada linha representa as instâncias de uma classe real, enquanto cada coluna representa as previsões do modelo para essas instâncias.

- **Elementos na diagonal principal (TP_i):** representam os verdadeiros positivos, ou seja, o número de amostras corretamente classificadas em cada classe.
- **Elementos fora da diagonal (FP_{ij}):** representam os falsos positivos, isto é, quantas amostras de uma classe real foram incorretamente classificadas como pertencentes a outra classe.
- Exemplo:
 - Se TP₁ = 30, isso significa que 30 amostras da classe C1 foram corretamente classificadas como C1;
 - Se FP₁₂ = 5, significa que 5 amostras que realmente pertenciam à classe C1 foram incorretamente classificadas como pertencendo à classe C2.

A análise da matriz de confusão permite identificar padrões de erro específicos, ajudando a entender se um modelo tem tendência a confundir certas classes. Por exemplo, se FP₁₂ e FP₂₁ forem elevados, isso indica uma confusão frequente entre as classes C1 e C2, sugerindo que ajustes no modelo ou no conjunto de dados podem ser necessários para melhorar a distinção entre essas classes.

4.3 Métricas de Classificação: Precisão, Revocação e F1-score

Além da acurácia, utilizamos o relatório de classificação gerado pela biblioteca `sklearn.metrics`, que inclui três métricas importantes:

4.3.1 Precisão (Precision)

A precisão é uma métrica fundamental para problemas de classificação, especialmente em cenários onde os falsos positivos podem ter um impacto significativo. Essa métrica calcula a proporção de instâncias classificadas como positivas pelo modelo que

realmente pertencem à classe positiva. Em termos matemáticos, a precisão é definida como:

$$\text{Precisão} = \frac{TP}{TP + FP} \quad (4.2)$$

Onde:

- TP (True Positives) representa os exemplos positivos corretamente classificados;
- FP (False Positives) refere-se aos exemplos incorretamente classificados como positivos.

A precisão é crucial em aplicações onde o custo de um falso positivo é alto, como em diagnósticos médicos (exemplo: identificar erroneamente um paciente saudável como doente) ou em sistemas de detecção de fraudes bancárias. Um modelo com alta precisão garante que as previsões positivas sejam confiáveis, reduzindo assim os erros associados à classificação indevida de amostras negativas como positivas (POWERS, 2011).

No entanto, a precisão isoladamente não fornece uma visão completa do desempenho do modelo, pois não leva em conta os falsos negativos. Por esse motivo, deve ser analisada juntamente com a revocação, especialmente em cenários onde há um forte desequilíbrio entre as classes (SOKOLOVA; LAPALME, 2009).

4.3.2 Revocação (Recall)

A revocação, também chamada de sensibilidade ou taxa de verdadeiros positivos, mede a capacidade do modelo de identificar corretamente todas as instâncias pertencentes à classe positiva. Sua fórmula é expressa como:

$$\text{Revocação} = \frac{TP}{TP + FN} \quad (4.3)$$

Onde:

- TP representa os verdadeiros positivos, ou seja, os exemplos corretamente classificados como positivos;
- FN (False Negatives) refere-se aos exemplos positivos que foram erroneamente classificados como negativos.

Essa métrica é particularmente relevante em aplicações onde perder uma instância positiva pode ter consequências graves. Por exemplo, em diagnósticos médicos para doenças graves, como o câncer, é preferível que um modelo tenha alta revocação para minimizar a quantidade de pacientes doentes que recebem um falso negativo (DAVIS;

GOADRICH, 2006). Da mesma forma, em sistemas de segurança, como detecção de ameaças em aeroportos, a revocação deve ser alta para evitar que um objeto perigoso passe despercebido.

No entanto, um modelo com alta revocação pode ter baixa precisão se ele classificar muitas instâncias negativas como positivas. Isso pode gerar um aumento nos falsos positivos, resultando em um modelo que detecta muitos casos, mas com pouca confiabilidade (SOKOLOVA; LAPALME, 2009). Por essa razão, a revocação geralmente deve ser analisada em conjunto com a precisão.

4.3.3 F1-score

O F1-score é a média harmônica entre precisão e revocação, sendo calculado como:

$$\text{F1-score} = 2 \times \frac{\text{Precisão} \times \text{Revocação}}{\text{Precisão} + \text{Revocação}} \quad (4.4)$$

Diferentemente da média aritmética, a média harmônica penaliza grandes diferenças entre a precisão e a revocação, garantindo que um modelo tenha um desempenho equilibrado em ambas as métricas. Se um modelo apresenta alta precisão, mas baixa revocação, ou vice-versa, o F1-score refletirá essa disparidade e tenderá a um valor mais baixo.

Essa métrica é amplamente utilizada em cenários de classificação desbalanceada, onde um modelo pode obter alta acurácia simplesmente prevendo sempre a classe majoritária. O F1-score, ao combinar precisão e revocação, fornece uma visão mais realista do desempenho do modelo (RIJSBERGEN, 1979). Ele é particularmente útil em tarefas como detecção de spam, reconhecimento de padrões em visão computacional e classificação de doenças em exames médicos.

Em algumas situações, variações do F1-score podem ser utilizadas para dar mais peso à precisão ou à revocação, dependendo da aplicação. O F2-score, por exemplo, dá mais importância à revocação, enquanto o F0.5-score prioriza a precisão (POWERS, 2011).

5 Resultados

Nesse projeto foram criados 4 modelos a fim de comparar os resultados entre eles e observar qual foi superior. Assim o primeiro modelo foi utilizado o dataset original sem nenhum filtro e teve os seguintes resultados:




Figura 9 – Matriz Confusão Modelo sem Filtros. Fonte: *Autor*.

Os experimentos realizados para a classificação dos níveis de Alzheimer com base em imagens de ressonância magnética revelaram desafios significativos no desempenho do modelo durante o treinamento, porém uma melhoria substancial na fase de teste.

O modelo obteve uma acurácia de 38,96% indicando dificuldades na aprendizagem das classes. A matriz de confusão revelou que a classe *non demented* foi a que apresentou o melhor desempenho, com um valor de 50% de precisão e recall. Por outro lado, as classes *moderate demented* e *mild demented* tiveram baixos índices de precisão e recall, com valores de 0% e 13%, respectivamente. O escore F1 para a classe *very mild demented* foi de 35%, sugerindo que o modelo teve dificuldades em distinguir corretamente os diferentes estágios da doença.

Já na fase de teste, o modelo apresentou uma melhoria expressiva na acurácia, atingindo 96,48%, o que indica um forte desempenho na generalização dos dados. A matriz de confusão para a validação sugere que a maioria das amostras foi corretamente classificada. Os valores de precisão, recall e F1-score demonstram um comportamento mais equilibrado, com médias superiores a 95%.

Os resultados indicam que, apesar do baixo desempenho durante o treinamento, o modelo conseguiu aprender de forma eficiente os padrões dos dados, resultando em uma alta acurácia na fase de teste. No entanto, a diferença entre as fases de treinamento e teste sugere que o modelo pode ter sofrido de *overfitting*, aprendendo características específicas do conjunto de treinamento, mas generalizando de forma limitada para novos dados.

O segundo modelo a ser testado, utilizou a filtragem de Sobel nas imagens de ressonância magnética para realce de bordas e melhor extração de características. Os resultados mostram um impacto positivo no desempenho do modelo em comparação com a abordagem sem o filtro.




Figura 10 – Matriz Confusão Filtro Sobel. Fonte: *Autor*.

Durante o treinamento, a acurácia obtida foi de 40,23%, um leve aumento em relação ao modelo sem o filtro. A matriz de confusão indica que a classe *non demented* continuou sendo a melhor classificada, com precisão e recall de 51%. A classe *very mild demented* apresentou uma ligeira melhora, atingindo um F1-score de 36%. Entretanto, a classe *moderate demented* permaneceu com desempenho insatisfatório, sem previsões corretas (precisão e recall de 0%).

Na fase de teste, a aplicação do filtro de Sobel resultou em uma acurácia de 94,21%, um leve decréscimo em relação ao modelo sem filtragem, mas ainda indicando um desempenho robusto. A matriz de confusão sugere que algumas amostras foram incorretamente classificadas, mas os valores médios de precisão, recall e F1-score continuam elevados, com macro média de 93% e média ponderada de 94%.

Os resultados sugerem que a aplicação do filtro de Sobel impactou a capacidade de generalização do modelo. Embora tenha havido um pequeno ganho na acurácia do treinamento, o desempenho na fase de teste foi ligeiramente inferior. Isso pode indicar que a filtragem destacou certos padrões úteis, mas também pode ter introduzido ruídos que dificultaram a distinção entre algumas classes.

Assim, o uso de técnicas de pré-processamento, como a filtragem de Sobel, mostrou-se uma abordagem promissora para a melhoria da extração de características, mas requer um ajuste fino para garantir um impacto positivo na classificação dos diferentes estágios do Alzheimer.

O terceiro modelo foi feito aplicando o filtro de Canny às imagens de ressonância magnética (Figura 11).




Figura 11 – Matriz Confusão Filtro Canny. Fonte: *Autor*.

Durante o treinamento, o modelo alcançou uma acurácia de 39,28%, apresentando um desempenho semelhante ao modelo sem filtragem e ao modelo com o filtro de Sobel. A matriz de confusão indica que a classe *non demented* foi novamente a melhor classificada, com precisão e recall de 50%, enquanto as classes *mild demented* e *very mild demented* tiveram desempenhos inferiores, com F1-scores de 13% e 35%, respectivamente. A classe *moderate demented* apresentou um desempenho ainda mais baixo, com precisão e recall de apenas 3%.

Na fase de teste, a acurácia obtida foi de 84,21%, demonstrando uma redução significativa em comparação aos experimentos anteriores. A matriz de confusão mostra um aumento nos erros de classificação, resultando em um impacto negativo na capacidade de generalização do modelo. A média ponderada dos escores F1 caiu para 84%, enquanto a média macro apresentou um valor ainda menor, 65%, indicando que algumas classes foram particularmente afetadas pela filtragem.

Os resultados sugerem que a aplicação do filtro de Canny pode ter removido informações importantes dos dados, prejudicando o aprendizado do modelo. Embora a detecção de bordas seja útil para destacar estruturas em imagens médicas, a abordagem utilizada pode ter sido excessivamente agressiva, resultando na perda de detalhes cruciais para a diferenciação dos estágios da doença.

Dessa forma, os experimentos indicam que a escolha do método de pré-processamento deve ser cuidadosamente avaliada, pois a filtragem inadequada pode impactar negativamente a capacidade do modelo de distinguir os diferentes estágios do Alzheimer. Ajustes nos parâmetros do filtro de Canny podem ser explorados em futuras abordagens para melhorar a performance da classificação.

Por fim, no último modelo ocorreu a aplicação de um filtro laplaciano, o qual também apresentou resultados distintos para as fases de treinamento e teste (figura 12).




Figura 12 – Matriz Confusão Filtro Laplaciano. Fonte: *Autor*.

Durante o treinamento, a acurácia atingiu 39,1%, evidenciando uma dificuldade do modelo em aprender padrões discriminativos entre as diferentes classes. Esse problema também pode ser observado na matriz de confusão e no relatório de classificação, onde as classes *mild demented* e *moderate demented* apresentaram baixas métricas de precisão, recall e F1-score. Em contrapartida, a classe *non demented* apresentou melhores resultados, com uma precisão de 50%, sugerindo que o modelo teve maior facilidade em identificar indivíduos sem demência.

Por outro lado, na fase de teste, a acurácia atingiu 95%, o que representa um aumento significativo em relação ao treinamento. Esse aumento pode indicar um possível sobreajuste do modelo aos dados de treinamento, fazendo com que ele generalize melhor para o conjunto de teste, mas sem garantir a mesma performance para novos dados. A matriz de confusão na fase de teste também revela uma maior assertividade na classificação, especialmente nas classes com maior número de amostras.

Os resultados sugerem que o modelo pode estar sofrendo com um desbalanceamento de dados e a complexidade das classes mais raras, como *moderate demented*. Além disso, o efeito do filtro laplaciano pode ter influenciado a extração de características, possivelmente dificultando a diferenciação entre níveis sutis da doença.

6 Conclusão

As implementações realizadas neste trabalho buscaram avaliar o impacto de diferentes técnicas de pré-processamento de imagens na classificação dos estágios de Alzheimer a partir de ressonâncias magnéticas. Foram aplicados os filtros Sobel, Canny e Laplaciano, cada um com o objetivo de destacar diferentes aspectos das imagens, e os resultados mostraram que a escolha do método de realce de bordas pode afetar significativamente o desempenho do modelo.

Durante o treinamento, todos os modelos apresentaram dificuldades em diferenciar corretamente os estágios da doença, com acurácias variando entre 39% e 40%. A classe *non demented* foi consistentemente a melhor classificada, com precisão e recall próximos a 50%, enquanto as classes *mild demented* e *moderate demented* demonstraram baixos desempenhos, sugerindo que o modelo teve dificuldades em aprender padrões discriminativos para essas categorias.

Já na fase de teste, os resultados foram distintos entre os filtros. O modelo sem filtragem atingiu 96% de acurácia, enquanto o uso dos filtros Sobel e Canny resultou em desempenhos ligeiramente inferiores, com 94% e 84%, respectivamente. O filtro Laplaciano, por outro lado, apresentou uma acurácia de 95%, indicando uma melhora significativa em relação à fase de treinamento, mas também levantando suspeitas de sobreajuste. A discrepância entre as acurácias de treinamento e teste sugere que o modelo pode não estar generalizando adequadamente para novos dados, possivelmente devido ao desbalanceamento das classes e à complexidade na diferenciação dos estágios iniciais da doença.

Os resultados indicam que a escolha do pré-processamento é um fator crítico para o desempenho do modelo e que técnicas adicionais podem ser exploradas para mitigar problemas identificados. O desbalanceamento de dados, por exemplo, pode ser tratado com técnicas como aumento de dados (*data augmentation*) ou reamostragem (*oversampling/undersampling*). Além disso, ajustes nos hiperparâmetros da rede neural e o uso de arquiteturas mais avançadas podem ajudar a melhorar a capacidade do modelo de identificar padrões sutis nas imagens.

Dessa forma, este estudo reforça a importância do pré-processamento na análise de imagens médicas e sugere que a combinação de diferentes técnicas pode ser uma abordagem promissora para aprimorar a classificação automática de Alzheimer, auxiliando no diagnóstico precoce e no monitoramento da doença.

Referências

- CANNY, J. A computational approach to edge detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 8, n. 6, p. 679–698, 1986. Citado na página 20.
- CORREIA, F. Machine learning approaches for alzheimer’s diagnosis using mri. *Medical Image Analysis*, v. 73, p. 55–66, 2023. Citado na página 15.
- DAVIS, J.; GOADRIC, M. The relationship between precision-recall and roc curves. In: *Proceedings of the 23rd International Conference on Machine Learning*. [S.l.: s.n.], 2006. p. 233–240. Citado na página 32.
- DERICHE, R. Using canny’s criteria to derive a recursively implemented optimal edge detector. *International journal of computer vision*, Springer, v. 1, n. 2, p. 167–187, 1987. Citado na página 21.
- DUMOULIN, V.; VISIN, F. A guide to convolution arithmetic for deep learning. *arXiv preprint arXiv:1603.07285*, 2016. Citado na página 19.
- FALAH.G.SALIEH. *Alzheimer MRI Dataset*. Hugging Face, 2023. Disponível em: https://huggingface.co/datasets/Falah/Alzheimer_MRI. Citado 2 vezes nas páginas 8 e 23.
- GOODFELLOW, I. *Deep learning*. [S.l.]: MIT press, 2016. Citado 2 vezes nas páginas 17 e 18.
- GU, J.; WANG, Z.; KUEN, J.; MA, L.; SHAHROUDY, A.; SHUAI, B.; LIU, T.; WANG, X.; WANG, G.; CAI, J. et al. Recent advances in convolutional neural networks. *Pattern recognition*, Elsevier, v. 77, p. 354–377, 2018. Citado na página 18.
- ISHIBE, T. Classification of alzheimer’s disease using cnns trained from scratch. *Journal of Neuroinformatics*, v. 45, n. 3, p. 204–215, 2022. Citado 2 vezes nas páginas 14 e 15.
- JACK, C. R.; HOLTZMAN, D. M. Biomarker modeling of alzheimer’s disease. *Neuron*, Elsevier, v. 80, n. 6, p. 1347–1358, 2013. Citado na página 11.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *nature*, Nature Publishing Group UK London, v. 521, n. 7553, p. 436–444, 2015. Citado na página 17.
- MARR, D.; HILDRETH, E. Theory of edge detection. *Proceedings of the Royal Society B: Biological Sciences*, v. 207, n. 1167, p. 187–217, 1980. Citado na página 21.
- MATOS, A. Adc maps for early detection of alzheimer’s disease. *Magnetic Resonance Imaging*, v. 30, n. 5, p. 767–776, 2012. Citado 2 vezes nas páginas 14 e 15.
- POWERS, D. M. W. Evaluation: From precision, recall and f-measure to roc, informedness, markedness correlation. *Journal of Machine Learning Technologies*, v. 2, n. 1, p. 37–63, 2011. Disponível em: <https://www.researchgate.net/publication/220557070>. Citado 2 vezes nas páginas 31 e 32.

- PRZEDBORSKI, S.; VILA, M.; JACKSON-LEWIS, V. et al. Series introduction: Neurodegeneration: What is it and where are we? *The Journal of clinical investigation*, Am Soc Clin Investig, v. 111, n. 1, p. 3–10, 2003. Citado na página 16.
- QUERFURTH, H. W.; LAFERLA, F. M. Alzheimer's disease. *New England Journal of Medicine*, Mass Medical Soc, v. 362, n. 4, p. 329–344, 2010. Citado na página 16.
- REIS, S. P.; MARQUES, M. L. D. G.; MARQUES, C. C. D. G. Diagnóstico e tratamento da doença de alzheimer. *Brazilian Journal of Health Review*, v. 5, n. 2, p. 5951–5963, 2022. Citado na página 16.
- RIJSBERGEN, C. J. V. *Information Retrieval*. 2nd. ed. [S.l.]: Butterworths, 1979. Citado na página 32.
- RUSSELL, S. J.; NORVIG, P. *Artificial intelligence: a modern approach*. [S.l.]: Pearson, 2016. Citado na página 17.
- SERAJ M., Y. e. a. Functional mri and k-nn for alzheimer's classification. *IEEE Transactions on Biomedical Engineering*, v. 66, n. 8, p. 2140–2147, 2019. Citado na página 15.
- SHORTEN, C.; KHOSHGOFTAAR, T. M. A survey on image data augmentation for deep learning. *Journal of Big Data*, v. 6, n. 60, 2019. Citado na página 19.
- SOBEL, I. An isotropic 3×3 image gradient operator. *Machine Vision for Three-Dimensional Scenes*, p. 376–379, 1990. Citado na página 19.
- SOKOLOVA, M.; LAPALME, G. A systematic analysis of performance measures for classification tasks. *Information Processing Management*, v. 45, n. 4, p. 427–437, 2009. Citado 2 vezes nas páginas 31 e 32.
- SOUSA, A. S. de; OLIVEIRA, G. S. de; ALVES, L. H. A pesquisa bibliográfica: princípios e fundamentos. *Cadernos da FUCAMP*, v. 20, n. 43, 2021. Citado na página 14.
- UFRN, U. F. d. R. G. d. N. Svm with polynomial kernel for alzheimer's detection. *Neurocomputing*, v. 320, p. 1128–1135, 2022. Citado 2 vezes nas páginas 14 e 15.