

ESCOLA DE ENFERMAGEM NOVA ESPERANÇA LTDA
FACULDADE DE ENFERMAGEM NOVA ESPERANÇA – FACENE

MARYNA RAYZA PAIVA DA SILVA

**USO DA INTELIGÊNCIA ARTIFICIAL NO IMAGEAMENTO POR RESSONÂNCIA
MAGNÉTICA PARA DIAGNÓSTICO DE DOENÇAS NEURODEGENERATIVAS**

JOÃO PESSOA

2025

MARYNA RAYZA PAIVA DA SILVA

**USO DA INTELIGÊNCIA ARTIFICIAL NO IMAGEAMENTO POR RESSONÂNCIA
MAGNÉTICA PARA DIAGNÓSTICO DE DOENÇAS NEURODEGENERATIVAS**

Trabalho de conclusão de curso apresentado à
Faculdade de Enfermagem Nova Esperança –
FACENE, como exigência para obtenção do
título de Tecnólogo em Radiologia.

ORIENTADOR: Prof. Dr. Alex Cristóvão
Holanda de Oliveira

JOÃO PESSOA

2025

MARYNA RAYZA PAIVA DA SILVA

**USO DA INTELIGÊNCIA ARTIFICIAL NO IMAGEAMENTO POR RESSONÂNCIA
MAGNÉTICA PARA DIAGNÓSTICO DE DOENÇAS NEURODEGENERATIVAS**

Trabalho de conclusão de curso apresentado pela aluna Maryna Rayza Paiva da Silva, do curso de Tecnologia em Radiologia da Faculdade de Enfermagem Nova Esperança – FACENE, tendo obtido o conceito de _____, conforme a apreciação da banca examinadora constituída pelos professores:

Aprovado em: _____ de _____ de _____

BANCA EXAMINADORA

Prof. Dr. Alex Cristóvão Holanda de Oliveira
Faculdade de Enfermagem Nova Esperança – FACENE

Prof. Dr. Arthur da Nóbrega Carreiro
Faculdade de Enfermagem Nova Esperança – FACENE

Prof. Dr. Kennedy Nascimento de Jesus
Faculdade de Enfermagem Nova Esperança – FACENE

USO DA INTELIGÊNCIA ARTIFICIAL NO IMAGEAMENTO POR RESSONÂNCIA MAGNÉTICA PARA DIAGNÓSTICO DE DOENÇAS NEURODEGENERATIVAS

SILVA, M. R. P.; OLIVEIRA, A. C. H.

RESUMO

Este trabalho apresenta uma revisão integrativa sobre a aplicação da inteligência artificial (IA) na análise de imagens de ressonância magnética (MRI) com foco no diagnóstico de doenças neurodegenerativas, especialmente Alzheimer (DA) e Parkinson (DP). A IA, por meio de técnicas como redes neurais convolucionais (CNN), Support Vector Machines (SVM) e Random Forest, tem se destacado por aprimorar a precisão diagnóstica, possibilitando a detecção precoce e o monitoramento da progressão dessas condições. O objetivo deste trabalho foi investigar a contribuição da IA para a melhoria do diagnóstico de doenças neurodegenerativas por meio do uso da MRI. Por meio de uma revisão bibliográfica integrativa, foram analisados diversos estudos que abordam a aplicação de técnicas de IA, incluindo redes neurais convolucionais, Support Vector Machines e Random Forest, que mostraram resultados promissores na identificação e monitoramento de condições neurológicas. A pesquisa analisou estudos publicados nos últimos anos, evidenciando abordagens inovadoras como aprendizado profundo, transferência de aprendizado, super-resolução de imagens e extração de características radiômicas. Os resultados indicam que a combinação de IA com MRI melhora significativamente a qualidade das imagens e a acurácia diagnóstica, permitindo a identificação de padrões cerebrais sutis muitas vezes imperceptíveis em análises tradicionais. Conclui-se que a IA representa um avanço promissor na medicina de precisão, com potencial para transformar o diagnóstico e a gestão de doenças neurológicas. No entanto, ressalta-se a importância de novas pesquisas que validem clinicamente esses modelos e promovam sua integração na prática médica.

PALAVRAS-CHAVE: Neurorradiologia. Diagnóstico. Tecnologia. Processamento. Análise.

USE OF ARTIFICIAL INTELLIGENCE IN MAGNETIC RESONANCE IMAGING FOR NEURODEGENERATIVE DISEASES DIAGNOSIS

ABSTRACT

This paper presents an integrative review on the application of artificial intelligence (AI) in the analysis of magnetic resonance images (MRI) with a focus on the diagnosis of neurodegenerative diseases, especially Alzheimer's (AD) and Parkinson's (PD). AI, through techniques such as convolutional neural networks (CNN), Support Vector Machines (SVM) and Random Forest, has stood out for improving diagnostic accuracy, enabling early detection and monitoring of the progression of these conditions. The objective of this work was to investigate the contribution of AI to improving the diagnosis of neurodegenerative diseases through the use of MRI. Through an integrative literature review, several studies that address the application of AI techniques, including convolutional neural networks, Support Vector Machines and Random Forest, were analyzed, which showed promising results in the identification and monitoring of neurological conditions. The research analyzed studies published in recent years, highlighting innovative approaches such as deep learning, transfer learning, image super-resolution and radiomic feature extraction. The results indicate that the combination of AI with MRI significantly improves image quality and diagnostic accuracy, allowing the identification of subtle brain patterns that are often imperceptible in traditional analyses. It is concluded that AI represents a promising advance in precision medicine, with the potential to transform the diagnosis and management of neurological diseases. However, it is important to highlight the importance of further research that clinically validates these models and promotes their integration into medical practice.

KEYWORDS:Neuroradiology. Diagnosis. Technology. Processing. Analysis.

INTRODUÇÃO

A inteligência artificial (IA) é uma das disciplinas mais recentes, tendo se originado após a Segunda Guerra Mundial, juntamente com o desenvolvimento dos computadores. Atualmente, essa área abrange uma ampla gama de subcampos, que vão desde domínios de aplicação geral, como aprendizado e percepção, até atividades específicas, como jogos de xadrez, demonstração de teoremas matemáticos, criação poética e diagnóstico de enfermidades. A IA é responsável por sistematizar e automatizar tarefas intelectuais, sendo, portanto, potencialmente pertinente a qualquer setor da atividade intelectual humana. Nesse contexto, ela se configura como um campo de abrangência universal (GOMES et al., 2010).

Na era da Medicina de Precisão, a IA se estabelece como uma ferramenta inovadora para a análise de imagens médicas, superando métodos tradicionais por sua eficiência na prática clínica. A introdução da IA no diagnóstico por imagem melhora a qualidade do atendimento, otimiza o processo de laudos e aumenta a precisão na interpretação dos resultados, permitindo que profissionais de saúde identifiquem padrões clínicos mais eficazmente (BARBOSA; PORTES, 2023; BATISTA et al., 2019; ROSÁRIO et al., 2023; TOMAS, 2023). Esse avanço é particularmente promissor no enfrentamento de doenças neurológicas degenerativas, onde a IA pode contribuir significativamente para a detecção precoce e o monitoramento da progressão clínica.

As doenças neurológicas degenerativas são distúrbios progressivos que resultam na perda gradual de neurônios e afetam o sistema nervoso, que inclui o cérebro, medula espinhal e nervos periféricos. Essas condições podem manifestar-se de diversas formas, influenciando tanto o movimento corporal quanto às funções cognitivas, sendo capazes de levar à demência. Com o envelhecimento da população global, o risco dessas doenças se torna cada vez mais relevante, com dados alarmantes mostrando que cerca de 50 milhões de pessoas em todo o mundo convivem com demências, das quais a doença de Alzheimer (DA) e a doença de Parkinson (DP) são as mais comuns (CARVALHO et al., 2023; SANTANA et al., 2024).

A DA, a principal causa de demência entre os idosos, caracteriza-se por deletérias alterações nas funções cognitivas, emocionais e comportamentais, implicando em fatores multifatoriais, como predisposição genética, idade e comorbidades (TORRÃO et al., 2012). Por outro lado, a DP se distingue por sintomas como tremores e rigidez, que podem

levar à instabilidade postural e comprometimento cognitivo, afetando a qualidade de vida dos indivíduos, especialmente os acima de 50 anos (CARVALHO et al., 2023).

Neste contexto, o imageamento por ressonância magnética (MRI – Magnetic Resonance Imaging) se destaca como um método de diagnóstico por imagem não invasiva com alta sensibilidade para a avaliação de estruturas cerebrais. Sua capacidade de gerar imagens precisas e em diferentes planos do corpo, aliada a uma excelente qualidade de contraste e resolução espacial, oferece inúmeras vantagens para o diagnóstico de doenças neurodegenerativas (HAGE et al., 2008).

O MRI é uma técnica de imagem médica que utiliza um campo magnético intenso e ondas de rádio para obter imagens detalhadas do corpo humano. Quando o corpo é exposto a esse campo magnético, os núcleos dos átomos, como o hidrogênio, alinham-se com o campo. A aplicação de pulsos de radiofrequência faz com que esses núcleos absorvam energia e, ao retornarem ao seu estado original, emitam sinais de rádio. Esses sinais são captados por antenas, chamadas de bobinas, e processados por computadores para formar imagens precisas dos tecidos internos (GOMES et al., 2019).

Na avaliação do cérebro e no diagnóstico preciso de doenças neurológicas, particularmente a DA e DP, o MRI é uma ferramenta essencial. Através da MRI, é possível descartar lesões secundárias e identificar padrões de atrofia cerebral característicos dessas doenças. A superioridade da MRI em termos de resolução anatômica e a capacidade de utilizar diversas técnicas de aquisição a tornam uma escolha preferencial para diagnósticos diferenciais em relação a outras demências (SCHILLING et al., 2022).

Os progressos nas técnicas de imagem têm proporcionado informações quantitativas valiosas sobre as doenças, permitindo a identificação de biomarcadores e a personalização do tratamento. A combinação de MRI com IA tem mostrado um potencial significativo para aprimorar diagnósticos, facilitando a identificação de características sutis que contribuem para a classificação de doenças neurodegenerativas e melhorando a rapidez e qualidade das imagens obtidas (SANTOS et al., 2019; SILVA et al., 2022).

O objetivo deste trabalho é, portanto, investigar a contribuição da IA para a melhoria do diagnóstico de doenças neurodegenerativas por meio do uso do MRI.

MATERIAL E MÉTODOS

Este estudo se trata de uma revisão bibliográfica integrativa sobre as ferramentas de IA para diagnóstico de doenças neurodegenerativas por meio do MRI, de modo a descrever as várias aplicações que têm sido desenvolvidas recentemente.

Os artigos foram pesquisados no buscador Google acadêmico e nas plataformas Scielo e Pubmed, utilizando as palavras-chave, em português: doença neurodegenerativa, Alzheimer, Parkinson, ressonância magnética e inteligência artificial; e em inglês: neurodegenerative disease, Alzheimer, Parkinson, magnetic resonance imaging e artificial intelligence. Foram selecionados artigos que foram publicados em português e inglês nos últimos 10 anos, disponibilizados integralmente, que abordam o desenvolvimento e/ou uso da IA em MRI para diagnóstico de doenças neurodegenerativas.

Nos resultados, são apresentados o funcionamento, as vantagens e as limitações das ferramentas de IA descritas nos artigos, considerando os tipos de aplicação.

RESULTADOS

Na Tabela 1, estão listados os artigos analisados neste trabalho, de acordo com os autores, ano de publicação, doença avaliada e técnica de IA utilizada. A seguir, são apresentados as metodologias e principais resultados desses artigos.

Pilipenko e colaboradores (2022) analisaram o desempenho de diferentes algoritmos de IA na classificação automática de imagens de MRI do cérebro, concentrando-se na diferenciação entre pacientes com demência frontotemporal (DFT) e indivíduos saudáveis. A pesquisa ressaltou que as técnicas Support Vector Machine (SVM) e Random Forest (RF) obtiveram os melhores desempenhos. A parte que destaca o bom desempenho das técnicas SVM e RF indica que, entre os algoritmos de aprendizado de máquina testados para diagnosticar degeneração lobar frontotemporal (FTD) com base em imagens de MRI funcional (fMRI), esses dois se mostraram mais eficazes. Especificamente, eles atingiram as maiores taxas de acurácia na identificação de pacientes com FTD em comparação com outros métodos, como K-Nearest Neighbors e Extra Trees. Esses resultados reforçam que SVM e RF são promissores para ajudar no diagnóstico precoce de doenças neurodegenerativas.

Tabela 1 - Artigos selecionados, de acordo com os autores, ano de publicação, doença avaliada e técnica utilizada.

AUTORES	ANO	DOENÇA	TÉCNICA DE INTELIGÊNCIA ARTIFICIAL
Archetti et al	2025	Alzheimer	O método Neuroharmony melhorou a qualidade e eficácia dos dados volumétricos cerebrais para diagnósticos.
Devi et al	2025	Parkinson's	Explorou aprendizado profundo para diagnosticar e monitorar Parkinson, personalizando estratégias de tratamento.
Irfan et al	2023	Alzheimer	Melhorou a qualidade das imagens de ressonância magnética para diagnóstico de Alzheimer.
Purrer et al	2023	Parkinson's	Usou IA para analisar imagens de ressonância magnética, melhorando diagnóstico e acompanhamento de doenças neurológicas.
Ramalho et al	2024	Alzheimer	Implementou uma rede neural para classificar ressonâncias, eficaz na distinção entre comprometimento cognitivo leve e saudável.
Stoleru et al	2023	Alzheimer	A técnica de IA utilizada é o transfer learning com redes neurais profundas (deep learning), especificamente utilizando os modelos pré-treinados ResNet-152 e AlexNet aplicados a imagens de ressonância magnética para diagnóstico de Alzheimer.
Abukaresh et al	2024	Parkinson's	Desenvolveu um modelo de IA para detectar Parkinson em estágios iniciais, melhorando diagnóstico e gestão da doença.
Bi et al	2021	Alzheimer's	Avaliou Deep Metric Learning para diagnosticar Alzheimer, superando outros métodos em precisão e sensibilidade.
Cruz et al	2023	Parkinson's	Integrou IA à neuroimagem para identificar padrões na doença de Parkinson, melhorando o diagnóstico automatizado.
Chen et al	2021	Parkinson's	Usou ressonância magnética para analisar a estimulação cerebral profunda em Parkinson, evidenciando benefícios clínicos.
Desai et al	2024	Parkinson's	Aplicou ressonância magnética 3D com aprendizado profundo, alcançando alta precisão no diagnóstico de doenças neurodegenerativas.
Li et al	2024	Parkinson's	Automatizou o diagnóstico de Parkinson com aprendizado profundo, aumentando a eficiência de distinção entre pacientes.
Reddy et al	2024	Parkinson's	Desenvolveu uma Rede Neural Convolutiva para diferenciar exames de ressonância magnética, facilitando diagnósticos mais precisos da doença de Parkinson.
Zhou et al	2024	Alzheimer's	Usou redes neurais para classificar a doença de Alzheimer a partir do volume hipocampal, aprimorando o diagnóstico.
Pilipenko	2022	Doenças Neurodegenerativas	Utilizou algoritmos de IA, como SVM e Random Forest, para classificar imagens cerebrais, melhorando o diagnóstico de demência frontotemporal.

Reddy e colaboradores (2024) criaram um modelo de IA usando redes neurais convolucionais (CNN) para identificar a DP a partir de exames de MRI. O modelo teve um desempenho excelente, alcançando 100% de precisão, sensibilidade, especificidade e acurácia, mostrando-se muito confiável para diferenciar pessoas com Parkinson de pessoas saudáveis. Além disso, o estudo identificou mudanças específicas nas imagens cerebrais dos pacientes com Parkinson, como atrofia na região do mesencéfalo, aumento do terceiro ventrículo, alterações no formato do cérebro e perda de volume nos lobos frontal e temporal. Esses achados reforçam o potencial da IA para ajudar os médicos no diagnóstico precoce e mais preciso da doença.

No estudo realizado por Cruz e colaboradores (2023), foi destacado que os modelos de aprendizado de máquina aplicados à neuroimagem têm grande potencial para identificar padrões e relações complexas que não são perceptíveis por métodos tradicionais de análise clínica. Esses modelos podem revelar alterações estruturais e funcionais cerebrais associadas à DP, contribuindo para a identificação de biomarcadores relevantes em diferentes estágios da doença. Entre os padrões possíveis estão sinais precoces na fase prodrômica, variações que permitem a estratificação em subtipos clínicos, indicadores da progressão da patologia e marcadores que predizem a resposta a terapias específicas. Além disso, esses sistemas podem auxiliar na diferenciação da DP em relação a outras doenças neurodegenerativas com sintomas semelhantes. Dessa forma, a aplicação dessas técnicas pode promover avanços significativos no diagnóstico precoce, no prognóstico individualizado e na personalização do tratamento da DP.

Chen e colaboradores (2021) analisaram os efeitos da estimulação cerebral profunda no núcleo subtalâmico (STN-DBS) em pacientes com DP, utilizando imagens de MRI otimizadas por algoritmos de IA. A análise precisa foi possível graças à aplicação de algoritmos de IA para melhorar a qualidade das imagens, aumentando a razão sinal-ruído (SNR) de 28,99 para 32,41 e a similaridade estrutural (SSIM) de 0,43 para 0,79, o que proporcionou maior nitidez e detalhamento nas observações. Os resultados revelaram melhorias clínicas significativas no grupo tratado com STN-DBS, incluindo reduções nas taxas de discinesia (5% - 35%) e flutuação motora (0% - 25%), além de melhora nas funções cognitivas e motoras, com aumento nos escores do MoCA e MMSE e redução no UPDRS. A MRI baseada em IA foi essencial para detectar com clareza as alterações neuropsiquiátricas, como a diminuição de edemas e sinais de sangramento, reforçando seu

papel como ferramenta crítica para diagnósticos mais precisos e acompanhamento da progressão da DP.

Desaia e colaboradores (2024) propuseram uma abordagem para o diagnóstico da DP, utilizando MRI 3D e modelos de aprendizado profundo. Com uma precisão de 90,13% na classificação entre pacientes e controles saudáveis, a técnica demonstrou ser altamente eficaz. A incorporação de técnicas de aumento de dados permitiu expandir o conjunto de dados, composto por 210 exames de indivíduos saudáveis e 970 de pacientes com Parkinson, melhorando a generalização do modelo e a precisão das previsões. Essa combinação de MRI 3D com aprendizado profundo representa um avanço significativo no diagnóstico e acompanhamento de doenças neurodegenerativas, abrindo novas possibilidades para a prática clínica.

Abukaresh (2024) desenvolveu um modelo de IA utilizando técnicas de aprendizado profundo para detectar a DP em estágios iniciais, empregando dados de imagens MRI obtidos da Parkinson's Progression Markers Initiative (PPMI). O conjunto de dados, composto por 1.207 imagens, incluindo 919 exames de MRI de indivíduos diagnosticados com DP e 288 de indivíduos saudáveis, foi pré-processado e aumentado para aumentar a robustez do modelo. Dois modelos de aprendizado de transferência, DenseNet121 e ResNet, foram implementados e ajustados, alcançando altas precisões de 88,50% e 92,50%, respectivamente, na distinção entre indivíduos afetados por DP e saudáveis. Essas descobertas ressaltam o potencial dos modelos de IA para auxiliar médicos na detecção precoce da DP, melhorando o diagnóstico e o gerenciamento da doença, ao mesmo tempo em que a utilização de modelos pré-treinados reduz a necessidade de grandes quantidades de dados rotulados.

Zhou e os demais autores (2024) avaliaram a capacidade preditiva de medições do volume hipocampal por MRI no risco de desenvolvimento da DA, utilizando IA e métodos baseados em evidências. A pesquisa, que envolveu 483 pacientes com DA, 756 com comprometimento cognitivo leve e 968 controles normais, empregou redes neurais convolucionais (InceptionResNetv2, Densenet169 e SEResNet50) para a classificação automatizada da DA a partir de imagens estruturais de MRI. O uso de um modelo de aprendizado profundo multitarefa e uma rede convolucional 3D densamente conectada permitiu aprimorar a precisão da previsão, enquanto uma meta-análise sistemática com 23 estudos revisados explorou o valor das medições do volume hipocampal para prever a ocorrência e progressão da DA. A técnica de aprendizado profundo oferece uma

ferramenta poderosa para diagnosticar e monitorar doenças neurodegenerativas de forma mais eficiente e automatizada.

Li e colaboradores (2024) apresentaram uma abordagem automatizada para diagnóstico da DP a partir de imagens de MRI ponderadas em T1, utilizando IA. Por meio de uma rede neural profunda (VB-net), o cérebro é segmentado em 109 regiões, das quais são extraídas milhares de características radiômicas que capturam detalhes estruturais sutis. Após seleção dos atributos mais relevantes, modelos de aprendizado de máquina, especialmente o SVM (máquina de vetores de suporte), são usados para diferenciar pacientes com Parkinson de indivíduos saudáveis com alta precisão. A técnica é rápida, objetiva e não invasiva, permitindo diagnósticos precoces e eficientes, com grande potencial para aplicação clínica no acompanhamento de doenças neurodegenerativas.

Bi e colaboradores (2021) avaliaram o uso do algoritmo de aprendizado profundo Deep Metric Learning (DML) para diagnosticar a DA a partir de imagens de MRI. Utilizando dados do banco de dados ADNI, o sistema de diagnóstico precoce baseado em DML foi comparado com o modelo de Redes Neurais Convolucionais (CNN) na classificação de DA, comprometimento cognitivo leve (MCI) e controles saudáveis (HC). O modelo DML demonstrou melhor precisão e sensibilidade na classificação de DA e HC, alcançando 0,83, superior ao modelo CNN, e também obteve melhores resultados para MCI. Além disso, o DML melhorou a velocidade de convergência, elevando a precisão e estabilidade na classificação, o que indica seu grande potencial para o diagnóstico precoce da DA.

Devi e colaboradores (2025) propuseram uma técnica inovadora baseada em redes neurais profundas para aprimorar a qualidade das imagens de MRI usadas no diagnóstico da DP. A principal abordagem utiliza Redes Adversariais Generativas com Super-Resolução (SRGAN), que combinam modelos como DeepResNet, técnicas de otimização e filtragem gaussiana para gerar imagens de altíssima definição. Esse aprimoramento permite revelar detalhes anatômicos sutis que passam despercebidos em imagens convencionais, aumentando a precisão na detecção precoce da doença. O modelo proposto superou outras redes conhecidas como VGG-19 e DenseNet em acurácia e sensibilidade, evidenciando sua utilidade clínica para identificar e acompanhar alterações cerebrais associadas à progressão da doença de forma mais eficaz e objetiva.

Purrer e outros pesquisadores (2025) adquiriram imagens de MRI em um scanner clínico de 3 Tesla, utilizando uma sequência de gradiente-eco rápido (MPRAGE)

ponderada em T1 3D, com alta resolução e parâmetros otimizados. Um software automatizado baseado em IA foi empregado para realizar análises quantitativas do volume cerebral, utilizando um modelo de segmentação de aprendizado profundo, a arquitetura U-Net, treinada em um extenso conjunto de dados de imagens 3D. Técnicas de aumento de dados foram implementadas para melhorar a aplicabilidade do modelo na prática clínica, permitindo a determinação precisa dos volumes de 42 regiões cerebrais, incluindo o hipocampo, e a comparação com imagens de indivíduos saudáveis. Essa abordagem não apenas aprimora a precisão no diagnóstico e acompanhamento de doenças neurodegenerativas, mas também facilita a identificação de alterações cerebrais precoces, contribuindo para um manejo mais eficaz das condições neurológicas.

Irfan e colaboradores (2023) utilizaram dados de MRI do banco de dados da Alzheimer's Disease Neuroimaging Initiative (ADNI), que contém informações rotuladas sobre a DA, comprometimento cognitivo leve (MCI) e indivíduos cognitivamente normais (CN). O conjunto de dados abrange 2.182 arquivos NIFTI, que oferecem visualizações 3D sagitais, coronais e transversais de cada paciente em diferentes visitas. Devido à presença de ruído nas imagens iniciais, uma parte do cérebro foi extraída para facilitar o processamento subsequente. O pré-processamento das imagens de MRI ponderadas em T1 foi realizado utilizando o kit de ferramentas CAT12 da SPM12, com etapas que incluíram remoção do crânio, normalização espacial e suavização, resultando em imagens uniformizadas com dimensões de $121 \times 145 \times 121$ mm e resolução espacial de $1,5 \times 1,5 \times 1,5$ mm³/voxel. Além disso, as intensidades dos sinais foram normalizadas para uma faixa de 0 a 1, otimizando a qualidade dos dados para análise. As visualizações 3D foram obtidas por meio de re-slicing, permitindo que cada fatia 2D fosse redimensionada para 145×145 mm, mantendo a resolução central e espacial da imagem original. Essa abordagem não apenas melhora a qualidade das imagens de MRI, mas também facilita o diagnóstico e o acompanhamento de doenças neurodegenerativas, contribuindo para uma compreensão mais profunda da progressão clínica e das alterações cerebrais associadas.

O Neuroharmony é um método inovador desenvolvido por Archetti e colaboradores (2025) que utiliza métricas de qualidade de imagem como preditores para eliminar efeitos relacionados ao scanner em dados volumétricos cerebrais, empregando regressão por Random Forest. Com o objetivo de integrar as interações entre a patologia da DA e as métricas de qualidade, os autores criaram uma extensão multiclasse do Neuroharmony que é aplicada a indivíduos com e sem comprometimento cognitivo. Através de experimentos

de validação cruzada, que envolveram 20.864 participantes e 43 scanners, foram comparadas as capacidades de diferentes estratégias em remover variações relacionadas ao scanner, ao mesmo tempo em que se preservava a habilidade de distinguir entre grupos diagnósticos. Os resultados mostraram que o modelo multiclasse proposto ofereceu uma concordância significativamente maior na identificação de marcadores entre scanners, superando modelos anteriores, especialmente em ambientes clínicos multicêntricos. Essa técnica não apenas melhora a qualidade dos dados volumétricos cerebrais, mas também garante a eficácia no diagnóstico e acompanhamento de doenças neurodegenerativas, como a DA, ao manter o sinal clínico relevante.

Um algoritmo de rede neural convolucional (CNN) foi desenvolvido e validado por Ramalho e colaboradores (2024), utilizando a Keras Sequential API em Python para analisar como o fatiamento de imagens de MRI ponderadas em T1 influencia a classificação entre pacientes com comprometimento cognitivo leve (MCI) e indivíduos saudáveis (NC). Para isso, foram selecionados 318 participantes, sendo 250 saudáveis e 68 com MCI, todos com pelo menos 16 anos de educação formal. Os dados foram organizados em conjuntos de treinamento, teste e validação na proporção de 70/15/15 para cada fatia de imagem. Os resultados mostraram que a CNN alcançou uma alta precisão na distinção entre os grupos, variando de 97% a 99%, conforme a fatia analisada, o número de épocas de treinamento e o tamanho do lote. Além da precisão, outros parâmetros, como F1-score, recall e precisão, apresentaram resultados superiores a 91%. Estes achados sugerem que a aplicação da CNN, especialmente com a escolha de cortes coronais, representa uma abordagem promissora para o diagnóstico precoce de doenças neurodegenerativas, facilitando a identificação de alterações cognitivas em estágios iniciais.

Os experimentos realizados por Stoleru e Iftene (2023) tiveram como objetivo identificar indivíduos com DA, abordando um desafio de classificação binária. Para isso, foi utilizado um sistema avançado que incluía quatro unidades de processamento gráfico NVIDIA RTX A6000, totalizando 180,6 TFLOPS de poder computacional, além de 48,7 GB de RAM e um processador AMD EPYC 7232P de 8 núcleos. Durante a fase de treinamento, foram aplicados modelos pré-treinados, como AlexNet e ResNet-152, da biblioteca de aprendizado profundo Fastai, que já haviam sido treinados no conjunto de dados ImageNet. Essa abordagem de usar modelos pré-treinados permite uma melhor extração de características relevantes e acelera a convergência durante o treinamento,

otimizando o desempenho. Foram conduzidos dois principais experimentos: um com o modelo AlexNet e outro com a ResNet-152, ambos treinados em conjuntos de dados originais e em dados sem crânio. Essa técnica não apenas melhora a identificação de pacientes com DA, mas também pode ser crucial para o acompanhamento e diagnóstico precoce de doenças neurodegenerativas, contribuindo para intervenções mais eficazes.

DISCUSSÃO

Na busca pelos artigos, foram considerados os artigos publicados nos últimos 10 anos que abordam a aplicação da IA no diagnóstico de doenças neurodegenerativas. Porém, os artigos selecionados (16) foram publicados nos últimos 6 anos, sendo sua maioria (14) publicada nos últimos 2 anos. A predominância de publicações recentes reflete o rápido desenvolvimento atual do campo da IA e sua integração com as técnicas de neuroimagem, especialmente por meio de imagens de MRI.

Além disso, a diversidade metodológica observada nos estudos revisados indica um rico panorama de abordagens para o diagnóstico precoce dessas doenças. As diferentes técnicas de aprendizado de máquina, como Support Vector Machine (SVM), Random Forest (RF) e redes neurais convolucionais (CNN), destacaram-se pelo alto desempenho na diferenciação entre pacientes e indivíduos saudáveis, apresentando maior exatidão em comparação com métodos como K-Nearest Neighbors e Extra Trees. Essas abordagens são fundamentais, pois a identificação precoce e a estratificação adequada dos pacientes podem levar a intervenções mais eficazes e personalizadas, melhorando a qualidade de vida dos afetados.

Outro ponto relevante é a capacidade da IA em revelar padrões sutis nas imagens de MRI que muitas vezes são difíceis de detectar por métodos tradicionais. Estudos como o de Reddy e colaboradores (2024) e Cruz e colaboradores (2023) destacam que a IA não só aprimora a precisão dos diagnósticos, mas também oferece insights sobre a progressão da doença, identificando biomarcadores que podem ser cruciais para acompanhamento clínico e para o desenvolvimento de terapias direcionadas. Isso sugere que a IA pode desempenhar um papel transformador na medicina de precisão, ao facilitar diagnósticos mais rápidos e eficientes.

No estudo de Chen e colaboradores (2021), a aplicação de algoritmos de IA para melhorar a qualidade das imagens de MRI resultou em uma análise mais precisa dos

efeitos da estimulação cerebral profunda em pacientes com DP. Aumentos significativos nas métricas de qualidade de imagem, como a razão sinal-ruído e a similaridade estrutural, permitiram uma avaliação mais clara das alterações neuropsiquiátricas. Essa pesquisa destaca como a combinação de IA com técnicas de imagem não apenas melhora a detecção de patologias, mas também integra o manejo clínico, visando melhores resultados para os pacientes.

Desaia e colaboradores (2024) focaram nas técnicas de aumento de dados em modelos de aprendizado profundo usando MRI 3D, alcançando uma precisão de 90,13% no diagnóstico de DP. A ênfase no uso de conjuntos de dados expandidos mostra uma abordagem prática para melhorar a robustez dos modelos de IA na prática clínica. Isso se alinha às descobertas de Abukaresh (2024), que também enfatizou a pré-processamento e o aumento de dados, utilizando modelos de aprendizado de transferência como DenseNet121 e ResNet para detectar DP em estágios iniciais, alcançando altas taxas de precisão. Ambas as pesquisas ressaltam a importância da preparação adequada de dados para maximizar o desempenho dos modelos de IA.

Zhou e colaboradores (2024) exploraram a predição do desenvolvimento da DA com medições do volume hipocampal e redes neurais convolucionais. O uso de um modelo multitarefa e uma estratégia baseada em redes profundas para a análise automatizada de imagens apresenta um avanço significativo e reflete a tendência atual de utilizar soluções de IA para lidar com múltiplas variáveis ao mesmo tempo, permitindo uma avaliação mais precisa do risco. Essa abordagem destaca que o contínuo aprimoramento em métodos de aprendizado profundo oferece um potencial promissor no diagnóstico e monitoramento das doenças neurodegenerativas.

A pesquisa de Li e colaboradores (2024) demonstrou a eficácia de uma rede neural profunda em segmentar o cérebro e extrair características radiômicas relevantes, sublinhando outra faceta da IA na análise de imagens médicas. A técnica de segmentação detalhada e a utilização de SVM para a classificação final propõem uma metodologia que combina a força da extração de características da IA com algoritmos de aprendizado de máquina, resultando em diagnósticos acelerados e mais precisos.

Dentre os diversos exemplos abordados, os trabalhos de Devi e colaboradores (2025) e Purrer e colaboradores (2025) destacam-se por suas abordagens inovadoras que envolvem super-resolução e modelos de segmentação avançados, respectivamente. A técnica SRGAN proposta por Devi enfatiza a importância de melhorar a qualidade das

imagens para a detecção precoce da DP, superando redes conhecidas em precisão. Por sua vez, a pesquisa de Purrer focou na segmentação com a arquitetura U-Net, permitindo a determinação precisa dos volumes cerebrais e a identificação de alterações precoces, reforçando assim a importância de um diagnóstico clínico eficiente e detalhado.

A aplicação de métodos computacionais complexos, como os utilizados por Irfan e colaboradores (2023) e Archetti e colaboradores (2025), demonstra a crescente integração da IA com a análise quantitativa em ambientes clínicos. As técnicas de ajuste e validação cruzada discutidas por Archetti mostram a importância da qualidade da imagem e a necessidade de desenvolver soluções que minimizem a variabilidade dos dados para garantir resultados diagnósticos mais precisos.

As técnicas que demonstraram melhor desempenho foram as CNNs, as SVMs e o algoritmo RF. Esses métodos apresentaram alta acurácia na diferenciação entre cérebros saudáveis e aqueles afetados por patologias como DA e DP, sendo capazes de identificar padrões sutis frequentemente imperceptíveis a métodos tradicionais.

As CNNs destacaram-se por sua eficácia na classificação de imagens cerebrais, sendo amplamente utilizadas em estudos recentes (RAMALHO et al., 2024; REDDY et al., 2024; STOLERU et al., 2023; ZHOU et al., 2024). Já as SVM mostraram excelente desempenho especialmente em conjuntos de dados reduzidos e bem estruturados (PILIPENKO et al., 2022; LI et al., 2024). O Random Forest teve papel relevante na padronização de imagens e na eliminação de ruídos, contribuindo para uma análise mais precisa (ARCHETTI et al., 2025; PILIPENKO et al., 2022).

O uso da técnica Transfer Learning também ampliou significativamente a eficiência diagnóstica, reduzindo a necessidade de grandes bases de dados e promovendo reaproveitamento de modelos robustos como ResNet e DenseNet (ABUKARESH et al., 2024; STOLERU et al., 2023).

Além disso, outras abordagens inovadoras complementaram os avanços da IA na área:

- O uso de SRGAN para super-resolução de imagens revelou detalhes importantes na doença de Parkinson;
- A U-Net permitiu segmentações cerebrais mais precisas;
- Modelos multitarefa 3D com CNNs foram utilizados na previsão da progressão do Alzheimer;

- A combinação de radiômica com SVM destacou-se na extração de biomarcadores estruturais;
- A otimização de imagens aumentou a nitidez diagnóstica em exames clínicos;
- Técnicas de harmonização multicêntrica mostraram-se eficazes na eliminação de variabilidades entre diferentes scanners de ressonância, ampliando a confiabilidade dos dados comparativos.

Esses resultados demonstram o potencial transformador da IA no diagnóstico precoce, na personalização do tratamento e na melhoria da qualidade das imagens na neuroimagem por ressonância magnética.

CONSIDERAÇÕES FINAIS

A pesquisa apresentada neste trabalho evidencia a importância crescente das técnicas de IA na área da medicina, especialmente no diagnóstico de doenças neurológicas degenerativas por meio de imagens de MRI. A IA, com suas diversas abordagens e algoritmos, como redes neurais convolucionais, Support Vector Machines e Random Forest, tem se mostrado uma ferramenta poderosa para melhorar a precisão dos diagnósticos, permitindo a identificação precoce de condições como DA e DP.

Portanto, diante dos fatos mencionados, é notório que as inovações em IA têm o potencial de transformar a prática clínica ao fornecer diagnósticos mais rápidos e precisos, à medida que os métodos se tornam mais sofisticados e integrados. No entanto, para que esse potencial seja plenamente realizado, é fundamental continuar investindo em pesquisas que explorem abordagens multimodais e garantam a validação clínica dos modelos de IA. Ao fazer isso, a comunidade médica poderá não apenas melhorar a detecção precoce de doenças neurodegenerativas, mas também personalizar intervenções terapêuticas, aumentando a qualidade de vida dos pacientes afetados.

REFERÊNCIAS BIBLIOGRÁFICAS

ABUKARESH, A. I.; OKATAN, A. AI - Based Early Detection of Parkinson's Disease using Mri: A Comparative Analysis of Densenet121 and Resnet Models. **Journal of Engineering and Applied Sciences**, 4, 2, 2024.

ARCHETTI, D.; VENKATRAGHAVAN, V.; WEISS, B.; BOURGEAT, P.; AUER, T.; VIDNYANSZKY, Z.; DURRLEMAN, S.; WIESJE, M.; BARKHOF, F.; ALEXANDER, D.C.; ALTMANN, A.; REDOLFI, A.; BETTY, M.; OXTOBY, N. P. A Machine Learning Model to Harmonize Volumetric Brain MRI Data for Quantitative Neuroradiologic Assessment of Alzheimer Disease. **Radiology: Artificial Intelligence**, 7, 1, 2025.

BARBOSA, L. M.; PORTES L. A. F. Revista Tecnologia Educacional, 16, 2023.

BI, X.; LIU, W.; LIU, H.; SHANG, Q. Artificial Intelligence-based MRI Images for Brain in Prediction of Alzheimer's Disease. **Journal of Healthcare Engineer**, 2021, 2021.

DEVI, B.; SRIVASTAVA, S.; VERMA, V. K. Enhancing Parkinson's Disease Detection from Brain MRI through Optimized Super Resolution Generative Network. **Advances in Nonlinear Variational Inequalities**, 28, 5, 2025.

IRFAN, M.; SHAHRESTANI, S.; ELKHODR, M. The Application of Deep Learning for Classification of Alzheimer's Disease Stages by Magnetic Resonance Imaging Data. **International Journal of Interactive Multimedia and Artificial Intelligence**, 9, 2023.

LI, C.; HUI, D.; WU, F.; XIA, Y.; SHI, F.; YANG, M.; ZHANG, J.; PENG, C.; FENG, J.; LI, C. Automatic diagnosis of Parkinson's disease using artificial intelligence based on routine T1-weighted MRI. **Frontiers in Medicine**, 10, 2024.

PILIPENKO, T.; GNUTTI, A.; SILVESTRI, A.; SERINA, I.; LEONARDI, R. Machine learning techniques for MRI feature-based detection of frontotemporal lobar degeneration. **Procedia Computer Science**, 207, 2022.

PURRER, V.; POHL, E.; LUECKEL, J. M.; BORGER, V.; SAUER, M.; RADBRUCH, A.; WULLNER, U.; SCHMEEL, F. C. Artificial-intelligence-based MRI brain volumetry in patients with essential tremor and tremor-dominant Parkinson's disease. **Brain Communications**, 5, 6, 2023.

RAMALHO, B. A. C.; BORTOLATO, L. R.; GOMES, N. D.; ANA, L. W.; NETO, F. E. P.; SILVA, M. A. A.; LACERDA, K. J. C.C. The impact of the orientation of MRI slices on the accuracy of Alzheimer's disease classification using convolutional neural networks (CNNs). **Journal of Medical Artificial Intelligence**, 7, 35, 2024.

REDDY, S.; GIRI, D.; PATEL, R. Diagnóstico de inteligência artificial da doença de Parkinson a partir de exames de ressonância magnética. **Cureus**, 16, 4, 2024.

ROSÁRIO, D. J.; ROGÉRIO, C. N.; PINTO, E. V. Inteligência Artificial na Radiologia. **Revista Ibero-Americana de Humanidades, Ciências e Educação**, 10, 5, 2024.

SCHILLING, L. P.; BALTHAZAR, M. L. F.; RADANOVIC, M.; FORLENZA, O. V.; SILAGI, M. L.; SMID, J.; BARBOSA, B. J. A. P.; FROTA, N. A. F.; SOUZA, L. C.; VALE, F. A. C.; CARAMELLI, P.; BERTOLUCCI, P. H. F.; CHAVES, M. L.F.; BRUCKI, S. M. D.; DAMASCENO, B. P.; NITRINI, R. Diagnóstico da doença de alzheimer: recomendações do departamento científico de neurologia cognitiva e do envelhecimento da academia brasileira de neurologia. **Dement Neuropsychol**, 16, 3, 2022.

STOLERU, G. I.; IFTENE, A. Transfer Learning for Alzheimer's Disease Diagnosis from MRI Slices: A Comparative Study of Deep Learning Models. **Procedia Computer Science**, 225, 2023.

ZHOUA, J.; ZHAOB, M.; YANG, Z.; CHENC, L.; LIUC, X. Exploring the Value of MRI Measurement of Hippocampal Volume for Predicting the Occurrence and Progression of Alzheimer's Disease Based on Artificial Intelligence Deep Learning Technology and Evidence-Based Medicine Meta-Analysis. **Journal of Alzheimer's Disease**, 97, 2024.

CARVALHO, L. F. C.; KOSTIC, V.; RODRIGUES, F. A. A. Doenças neurodegenerativas associadas com as fases da vida. **Contribuciones a Las Ciencias Sociales**, 16, 7, 2023.

SANTANA, C. C. P.; SILVA, R. O.; FERREIRA, P. A. A influência da dieta nos quadros de doenças degenerativas na população idosa. **Research, Society and Development**, 13, 6, 2024.

SANTOS, M. K.; JÚNIOR, J. R. F.; WADA, D. T.; TENÓRIO, A. P. M.; BARBOSA, M. H.N.; MARQUES, P. M. A. Inteligência artificial, aprendizado de máquina, diagnóstico auxiliado por computador e radiômica: avanços da imagem rumo à medicina de precisão. **Radiologia Brasileira**, 52, 6, 2019.

SILVA FILHO, W. S.; OLIVEIRA, R. M. S. A importância da inteligência artificial na radiologia: uma revisão sistemática de literatura. **Brazilian Journal of Review**, 5, 4, 2022.