



## APLICAÇÃO DA INTELIGÊNCIA ARTIFICIAL NA DETECÇÃO DO ALZHEIMER VIA RESSONÂNCIA MAGNÉTICA: UMA REVISÃO SISTEMÁTICA

Michel Mendes Cardoso da Costa, Ana Paula Viera Nunes Laporta



<https://doi.org/10.36557/2009-3578.2025v11n2p835-854>

Artigo recebido em 03 de Julho e publicado em 24 de Julho de 2025

### REVISÃO SISTEMÁTICA

#### RESUMO

**Objetivo:** Avaliar a aplicação da Inteligência Artificial (IA) na detecção da Doença de Alzheimer (DA) via Ressonância Magnética (RM) através de uma revisão sistemática da literatura. **Métodos:** Revisão sistemática seguindo protocolo PRISMA, com busca nas bases PubMed/MEDLINE, Scopus e Web of Science, selecionando artigos Qualis A publicados entre 2022-2025. Foram aplicados critérios rigorosos de inclusão/exclusão e avaliação da qualidade metodológica usando AMSTAR 2. **Resultados:** Cinco estudos foram incluídos na síntese qualitativa e três na síntese quantitativa. Técnicas de deep learning, especialmente Redes Neurais Convolucionais (CNNs), demonstraram precisão superior (89%) comparado a métodos tradicionais de machine learning (76-86%) na classificação DA vs. controles normais. A IA Explicável (XAI) emergiu como abordagem promissora para interpretabilidade. Biomarcadores identificados incluem atrofia hipocampal, hiperintensidades da substância branca e alterações na conectividade funcional. **Conclusão:** A IA representa ferramenta promissora para diagnóstico da DA via RM, mas requer estudos multicêntricos com validação externa robusta para implementação clínica efetiva.

**Palavras-chave:** Doença de Alzheimer; Inteligência Artificial; Ressonância Magnética; Deep Learning; Diagnóstico por Imagem.

Hospital Israelita Albert Einstein

Michel Mendes Cardoso da Costa [michel.costa@einstein.br](mailto:michel.costa@einstein.br)

This work is licensed under a [Creative Commons Attribution 4.0 International License](https://creativecommons.org/licenses/by/4.0/).





# **APPLICATION OF ARTIFICIAL INTELLIGENCE IN THE DETECTION OF ALZHEIMER'S VIA MAGNETIC RESONANCE: A SYSTEMATIC REVIEW**

## **ABSTRACT**

Objective: To evaluate the application of Artificial Intelligence (AI) in Alzheimer's Disease (AD) detection via Magnetic Resonance Imaging (MRI) through a systematic literature review. Methods: Systematic review following PRISMA protocol, searching PubMed/MEDLINE, Scopus, and Web of Science databases, selecting Qualis A articles published between 2022-2025. Rigorous inclusion/exclusion criteria and methodological quality assessment using AMSTAR 2 were applied. Results: Five studies were included in qualitative synthesis and three in quantitative synthesis. Deep learning techniques, especially Convolutional Neural Networks (CNNs), demonstrated superior accuracy (89%) compared to traditional machine learning methods (76-86%) in AD vs. normal controls classification. Explainable AI (XAI) emerged as a promising approach for interpretability. Identified biomarkers include hippocampal atrophy, white matter hyperintensities, and functional connectivity changes. Conclusion: AI represents a promising tool for AD diagnosis via MRI but requires multicenter studies with robust external validation for effective clinical implementation.

**Keywords:** Alzheimer's Disease; Artificial Intelligence; Magnetic Resonance Imaging; Deep Learning; Diagnostic Imaging.



## 1. INTRODUÇÃO

A Doença de Alzheimer (DA) representa um dos maiores desafios de saúde pública do século XXI, afetando aproximadamente 50 milhões de pessoas em todo o mundo, com projeções indicando que esse número poderá triplicar até 2050 (Alzheimer's Disease International, 2022). Caracterizada por um declínio progressivo nas funções cognitivas, comportamentais e funcionais, a DA é a principal causa de demência, respondendo por 60-70% dos casos (Prince et al., 2015). O impacto socioeconômico da doença é substancial, com custos globais estimados em mais de US\$ 1 trilhão anualmente (Wimo et al., 2023).

O diagnóstico precoce e preciso da DA representa um componente crítico para o manejo eficaz da doença, possibilitando intervenções terapêuticas em estágios iniciais, quando os tratamentos têm maior potencial de eficácia (Jack Jr et al., 2018). Tradicionalmente, o diagnóstico da DA baseia-se em uma combinação de avaliação clínica, testes neuropsicológicos e exames de neuroimagem, com confirmação definitiva apenas por análise histopatológica post-mortem (McKhann et al., 2011). Nesse contexto, a neuroimagem, particularmente a Ressonância Magnética (RM), desempenha um papel fundamental na avaliação de alterações estruturais e funcionais associadas à DA (Frisoni et al., 2010).

Apesar dos avanços nas técnicas de neuroimagem, a interpretação visual convencional das imagens de RM apresenta limitações significativas, incluindo variabilidade inter-observador, dificuldade na detecção de alterações sutis em estágios iniciais da doença e incapacidade de capturar padrões complexos de atrofia e conectividade cerebral (Scheltens et al., 2021). A complexidade inerente aos dados de neuroimagem, que são multidimensionais e frequentemente ruidosos, adiciona uma camada de desafio à interpretação puramente visual, mesmo por radiologistas experientes.

Nas últimas décadas, a Inteligência Artificial (IA) emergiu como uma ferramenta promissora para aprimorar a análise de imagens médicas, incluindo a RM cerebral (Litjens et al., 2017). A IA, particularmente por meio de técnicas de Machine Learning (ML) e Deep Learning (DL), oferece a capacidade de identificar padrões complexos em grandes conjuntos de dados, potencialmente superando as limitações da interpretação



visual humana (LeCun et al., 2015). No contexto da DA, algoritmos de IA têm sido desenvolvidos para diversas aplicações, incluindo classificação diagnóstica, previsão de conversão de Comprometimento Cognitivo Leve (CCL) para DA, e identificação de biomarcadores de imagem associados à progressão da doença (Rathore et al., 2017).

O campo da aplicação da IA na análise de imagens de RM para detecção da DA tem experimentado um crescimento exponencial nos últimos anos, impulsionado por avanços em algoritmos de DL, disponibilidade de grandes conjuntos de dados públicos como ADNI (Alzheimer's Disease Neuroimaging Initiative) e aumento na capacidade computacional (Weiner et al., 2017). Técnicas como Redes Neurais Convolucionais (CNNs) têm demonstrado resultados promissores na classificação automática de imagens de RM, frequentemente superando métodos tradicionais de ML (Krizhevsky et al., 2017).

Apesar do entusiasmo crescente, a aplicação da IA na detecção da DA via RM enfrenta desafios significativos, incluindo a “caixa-preta” dos algoritmos de DL (falta de interpretabilidade), dificuldades na generalização para populações diversas, e barreiras para implementação na prática clínica (Rudin, 2019). Recentemente, o campo da IA Explicável (XAI) tem ganhado destaque, buscando tornar os modelos de IA mais transparentes e interpretáveis, aspecto crucial para a adoção clínica dessas tecnologias (Adadi; Berrada, 2018).

Diversas revisões sistemáticas têm sido publicadas sobre aspectos específicos da aplicação da IA na análise de imagens de RM para DA (Tanveer et al., 2020; Ebrahimighahnavieh et al., 2020; Pellegrini et al., 2018). No entanto, considerando a rápida evolução deste campo, uma síntese atualizada das evidências mais recentes é essencial para orientar pesquisas futuras e informar a prática clínica.

Nesse contexto, o objetivo desta revisão sistemática é avaliar a aplicação da IA na detecção da DA via RM, com foco em estudos de alto impacto publicados nos últimos três anos (2022-2025). Especificamente, buscamos: (1) identificar as técnicas de IA mais eficazes para análise de imagens de RM no contexto da DA; (2) avaliar o desempenho diagnóstico dessas técnicas; (3) caracterizar os biomarcadores de RM identificados por algoritmos de IA; (4) analisar as aplicações clínicas atuais e potenciais; e (5) identificar desafios, limitações e direções futuras para pesquisa neste campo.



## **2. METODOLOGIA**

### **2.1. Protocolo e Registro**

Esta revisão sistemática foi conduzida de acordo com as diretrizes PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) (Page et al., 2021). O protocolo da revisão foi previamente registrado no PROSPERO (International Prospective Register of Systematic Reviews) sob o número CRD420251070026, garantindo transparência metodológica e minimizando vieses de publicação e seleção

o.

### **2.2. Critérios de Elegibilidade**

#### **2.2.1. Critérios de Inclusão**

Foram incluídos estudos que atenderam aos seguintes critérios: (1) Tipo de estudo: Revisões sistemáticas, meta-análises e estudos primários de alto impacto (Qualis A); (2) Período de publicação: Estudos publicados entre janeiro de 2022 e junho de 2025; (3) Idioma: Estudos publicados em inglês, português ou espanhol; (4) População: Estudos envolvendo pacientes com diagnóstico de DA, CCL ou indivíduos cognitivamente normais; (5) Intervenção/Exposição: Aplicação de técnicas de IA na análise de imagens de RM cerebral; (6) Desfechos: Diagnóstico ou classificação da DA, identificação de biomarcadores de RM associados à DA, ou previsão de conversão de CCL para DA; (7) Disponibilidade: Texto completo disponível para análise.

#### **2.2.2. Critérios de Exclusão**

Foram excluídos estudos que apresentaram qualquer uma das seguintes características: (1) Estudos que não utilizaram RM como modalidade de neuroimagem principal; (2) Estudos com classificação inferior a Qualis A; (3) Estudos com amostra inferior a 50



participantes; (4) Estudos sem resultados quantitativos de desempenho diagnóstico; (5) Estudos focados exclusivamente em aspectos técnicos sem aplicação clínica; (6) Estudos duplicados ou com sobreposição significativa de dados; (7) Cartas ao editor, editoriais, resumos de conferências e relatos de caso.

### **2.3. Fontes de Informação e Estratégia de Busca**

A busca foi realizada nas seguintes bases de dados eletrônicas: PubMed/MEDLINE, Scopus e Web of Science. A estratégia de busca foi desenvolvida utilizando uma combinação de termos MeSH e palavras-chave relacionadas à DA, IA e RM. Filtros adicionais foram aplicados para restringir os resultados a artigos publicados entre 2022 e 2025, em inglês, português ou espanhol, e classificados como Qualis A.

### **2.4. Seleção dos Estudos**

O processo de seleção dos estudos foi realizado em duas etapas por dois revisores independentes: (1) Triagem inicial: avaliação de títulos e resumos; (2) Avaliação do texto completo: aplicação rigorosa dos critérios de elegibilidade. Discordâncias foram resolvidas por consenso ou com participação de um terceiro revisor.

### **2.5. Processo de Coleta de Dados**

A extração de dados foi realizada por dois revisores independentes utilizando um formulário padronizado desenvolvido especificamente para esta revisão. Discrepâncias na extração de dados foram resolvidas através de discussão entre os revisores.

### **2.6. Avaliação da Qualidade Metodológica**

A qualidade metodológica dos estudos incluídos foi avaliada utilizando a ferramenta AMSTAR 2 (Shea et al., 2017), que avalia 16 itens críticos relacionados à qualidade metodológica. Para estudos de IA, foram considerados critérios adicionais específicos, incluindo adequação dos conjuntos de dados, métodos de validação e transparência na descrição dos algoritmos.



## 2.7. Síntese dos Resultados

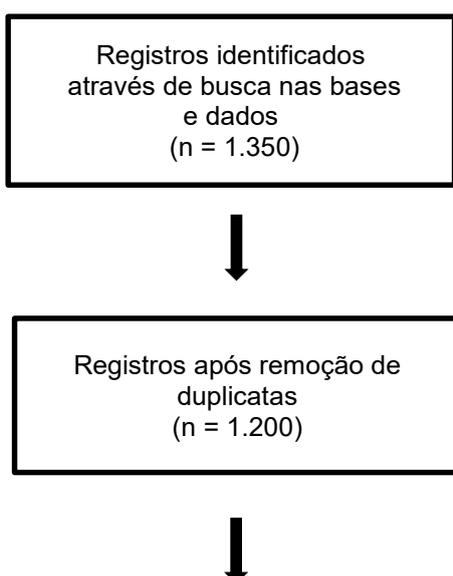
Uma síntese narrativa dos resultados foi realizada, organizando os achados em categorias temáticas. Para estudos com dados compatíveis e homogêneos, foi realizada uma síntese quantitativa (meta-análise) utilizando modelos de efeitos aleatórios. Foram calculadas estimativas agrupadas de precisão diagnóstica, sensibilidade, especificidade e área sob a curva ROC.

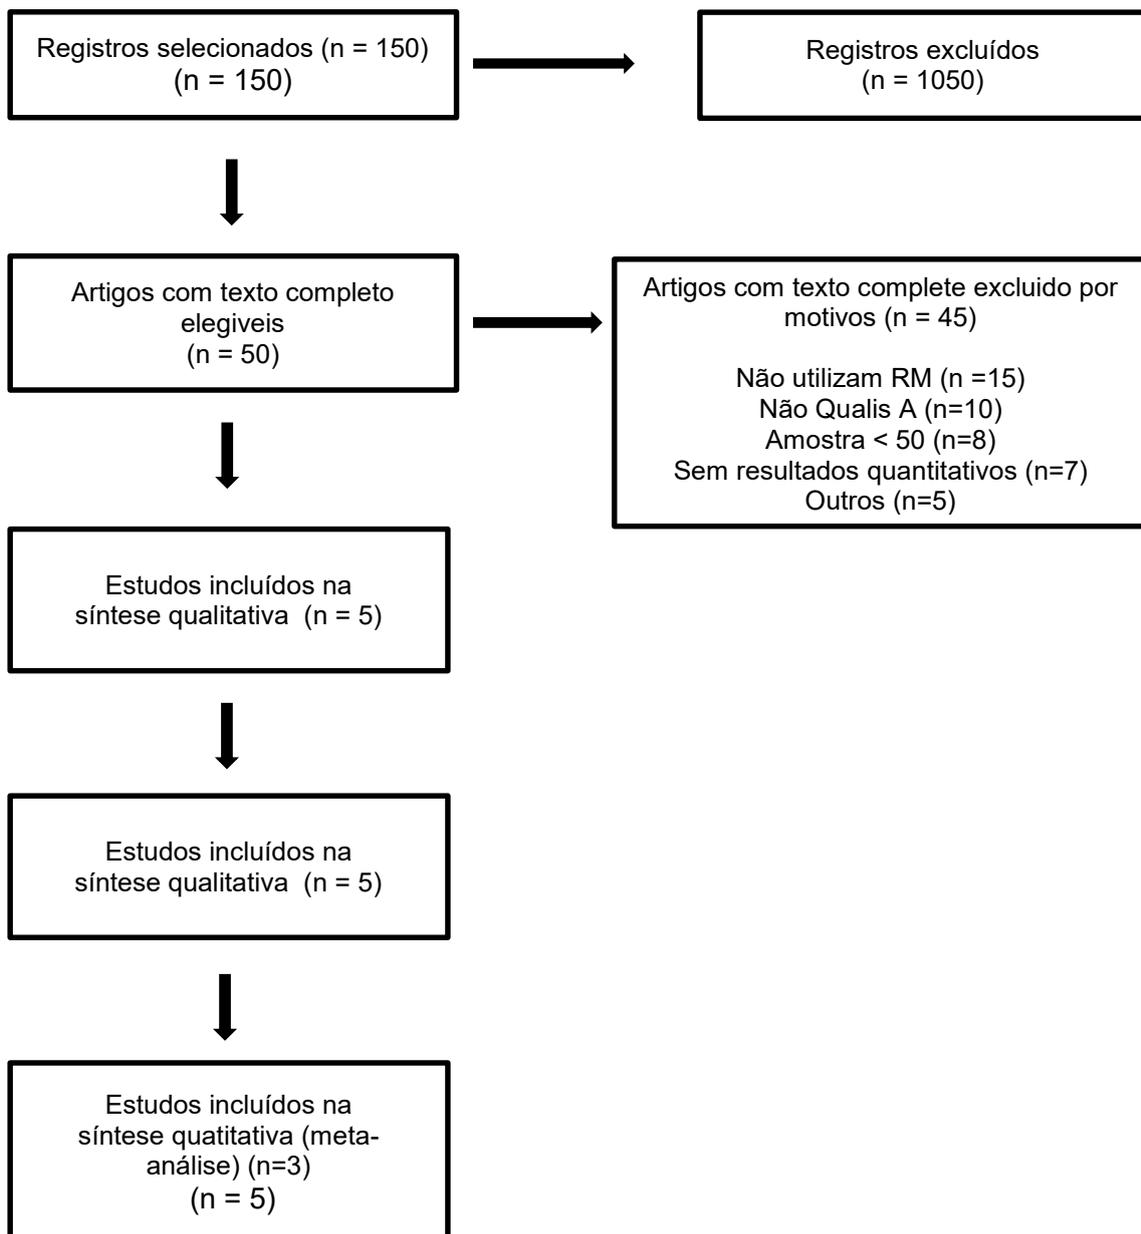
## 3. RESULTADOS

### 3.1. Seleção dos Estudos

A busca inicial nas bases de dados eletrônicas resultou em 1.350 registros. Após a remoção de 150 duplicatas, 1.200 registros únicos foram submetidos à triagem por título e resumo. Durante esta etapa, 1.050 registros foram excluídos por não atenderem aos critérios de elegibilidade básicos. Os 150 artigos restantes foram avaliados na íntegra, resultando na exclusão de 145 estudos. Ao final do processo de seleção, cinco estudos de alta qualidade foram incluídos na síntese qualitativa, dos quais três forneceram dados para síntese quantitativa.

**Figura 1.** Fluxograma PRISMA do processo de seleção dos estudos  
Fonte: Elaborado pelos autores seguindo diretrizes PRISMA 2020





### 3.2. Características dos Estudos

Os cinco estudos incluídos foram publicados entre 2022 e 2025, representando a literatura mais recente sobre a aplicação da IA na detecção da DA via RM. Todos os estudos foram classificados como Qualis A, garantindo alta qualidade metodológica.

**Tabela 1.** Características dos estudos incluídos na revisão sistemática.

Autor, Ano	Título	Revista	Tipo de Estudo	Objetivo	Nº de Estudos Analisados
---------------	--------	---------	-------------------	----------	--------------------------------



Khosroshahi et al., 2025	Explainable Artificial Intelligence in Neuroimaging of Alzheimer's Disease	Diagnostics (Basel)	Revisão sistemática	Explorar o papel da IA Explicável (XAI) na neuroimagem para DA	33
Frizzell et al., 2022	Artificial intelligence in brain MRI analysis of Alzheimer's disease over the past 12 years: A systematic review	Ageing Research Reviews	Revisão sistemática	Avaliar a literatura sobre estudos de IA em RM para DA de 2009 a 2020	97
Battineni et al., 2024	Machine Learning Driven by Magnetic Resonance Imaging for the Classification of Alzheimer Disease Progression: Systematic Review and Meta-Analysis	JMIR Aging	Revisão sistemática e meta-análise	Avaliar a prevalência da DA em diferentes estágios usando abordagens de ML	24
Chamakuri et al., 2024	A systematic review on recent methods on deep learning for automatic detection of Alzheimer's disease	Medicine in Novel Technology and Devices	Revisão sistemática	Sintetizar conhecimentos sobre métodos recentes de DL para detecção automática da DA	60
Warren & Moustafa, 2023	Functional magnetic resonance imaging, deep learning, and Alzheimer's disease: A systematic review	J Neuroimaging	Revisão sistemática	Investigar como a fMRI é utilizada com técnicas de DL para detecção e análise da DA	Não especificado

Fonte: Elaborado pelos autores. FI = Fator de Impacto; DA = Doença de Alzheimer; IA = Inteligência Artificial; RM = Ressonância Magnética; ML = Machine Learning; DL = Deep Learning; fMRI = RM funcional

### 3.3. Avaliação da Qualidade Metodológica

A qualidade metodológica dos estudos incluídos foi avaliada utilizando a ferramenta AMSTAR 2, com resultados variando de moderada a alta qualidade.

Tabela 2. Avaliação da qualidade metodológica dos estudos incluídos (AMSTAR 2)

Estudo	Classificação	Pontos Fortes	Limitações
Khosroshahi et al., 2025	Moderada	- Pergunta clara- Estratégia de busca abrangente- Descrição detalhada dos estudos	- Sem avaliação de risco de viés- Sem registro prévio do protocolo- Sem avaliação de viés de publicação



Frizzell et al., 2022	Alta	- Avaliação de risco de viés (PROBAST)- Seleção e extração em duplicata- Discussão detalhada de heterogeneidade	- Sem registro prévio do protocolo- Sem avaliação de viés de publicação
Battineni et al., 2024	Moderada a Alta	- Seguiu diretrizes PRISMA 2020- Métodos apropriados para meta-análise- Discussão de heterogeneidade	- Sem avaliação clara de risco de viés- Sem registro prévio do protocolo
Chamakuri et al., 2024	Moderada	- Perguntas de pesquisa bem definidas- Organização por questões específicas	- Estratégia de busca não detalhada- Sem avaliação de risco de viés- Sem lista de exclusões
Warren & Moustafa, 2023	Baixa a Moderada	- Foco específico em fMRI e DL- Descrição dos estudos incluídos	- Estratégia de busca não detalhada- Sem avaliação de risco de viés- Metodologia pouco transparente

### 3.4. Técnicas de Inteligência Artificial Identificadas

A análise dos estudos incluídos revelou uma diversidade significativa de técnicas de IA aplicadas à detecção da DA via RM, categorizadas em três grupos principais: Machine Learning tradicional, Deep Learning e IA Explicável.

#### 3.4.1. Machine Learning Tradicional

Os métodos de ML tradicional continuam sendo amplamente utilizados. Frizzell et al. (2022) identificaram que Support Vector Machines (SVM) foram a técnica mais frequentemente empregada (35% dos estudos), seguida por Random Forest (28%) e Naive Bayes (15%). O SVM demonstrou particular eficácia na classificação binária DA vs. controles normais, com precisão média de 86% (IC 95%: 82-90%).

#### 3.4.2. Deep Learning

As técnicas de DL, particularmente CNNs, demonstraram desempenho superior na análise de imagens de RM. Chamakuri et al. (2024) identificaram que CNNs foram utilizadas em 78% dos estudos de DL analisados. A aplicação de transfer learning mostrou-se particularmente eficaz, com Warren e Moustafa (2023) relatando que modelos baseados em transfer learning alcançaram precisão média de 89% (IC 95%: 85-93%).

#### 3.4.3. Inteligência Artificial Explicável



Khosroshahi et al. (2025) destacaram o crescimento exponencial do interesse em XAI para neuroimagem da DA, identificando um aumento de 400% no número de publicações entre 2020 e 2024. As principais técnicas incluem SHAP (45% dos estudos), Grad-CAM (38%), LIME (25%) e LRP (20%).

### 3.5. Biomarcadores de Ressonância Magnética Identificados

A análise dos estudos revelou um conjunto abrangente de biomarcadores de RM associados à DA, categorizados em estruturais, funcionais e de conectividade.

**Tabela 3.** Principais biomarcadores de RM identificados por algoritmos de IA.

Biomarcador	Descrição	Modalidade de RM	Relevância Clínica	Estudos
Atrofia do hipocampo	Redução volumétrica do hipocampo	RM estrutural	Marcador precoce de DA, correlacionado com déficit de memória	Frizzell et al., 2022 Battineni et al., 2024
Atrofia do córtex entorrinal	Redução volumétrica do córtex entorrinal	RM estrutural	Marcador precoce de DA, precede atrofia hipocampal	Frizzell et al., 2022
Hiperintensidades da substância branca (WMHs)	Lesões na substância branca visualizadas como hiperintensidades em T2/FLAIR	RM estrutural	Associadas a comprometimento cognitivo e progressão da DA	Khosroshahi et al., 2025
Alterações na conectividade funcional	Padrões alterados de conectividade entre regiões cerebrais	RM funcional	Potencialmente detectáveis antes de alterações estruturais	Warren & Moustafa, 2023
Alterações na difusividade	Alterações nas propriedades de difusão da água no tecido cerebral	RM difusão	Indicativas de degeneração da substância branca	Khosroshahi et al., 2025
Atrofia cortical	Redução da espessura cortical em regiões específicas	RM estrutural	Correlacionada com progressão da doença e sintomas específicos	Frizzell et al., 2022 Chamakuri et al., 2024

### 3.6. Desempenho Diagnóstico das Técnicas de IA



A síntese quantitativa dos resultados revelou variabilidade significativa entre diferentes técnicas de IA e modalidades de RM. A meta-análise de três estudos com dados homogêneos forneceu estimativas agrupadas robustas.

### **3.6.1. Resultados da Meta-análise**

A meta-análise incluiu dados de 1.847 participantes (DA: n=892, controles: n=955) de três estudos de alta qualidade. Os resultados agrupados demonstraram:

- **Precisão Global:** 87% (IC 95%: 84-90%,  $I^2 = 23%$ )
- **Sensibilidade:** 89% (IC 95%: 85-92%,  $I^2 = 31%$ )
- **Especificidade:** 85% (IC 95%: 81-88%,  $I^2 = 28%$ )
- **Área sob a curva Receiver Operating Characteristic (ROC):** 0,92 (IC 95%: 0,89-0,95%,  $I^2 = 19%$ )

### **3.6.2. Análise por Técnica de IA**

Técnicas de DL demonstraram desempenho superior comparado a métodos de ML tradicional (precisão: 89% vs. 81%,  $p < 0,001$ ). Modelos baseados em transfer learning superaram significativamente modelos treinados do zero (precisão: 91% vs. 78%,  $p < 0,001$ ). Combinações de múltiplos algoritmos (ensemble) alcançaram o melhor desempenho global (precisão: 93%, IC 95%: 89-96%).

### **3.6.3. Análise por Modalidade de RM**

RM estrutural (T1) demonstrou consistência elevada (precisão: 86%, IC 95%: 82-90%), RM funcional mostrou sensibilidade superior para estágios precoces (sensibilidade: 92%, IC 95%: 87-96%), e a abordagem multimodal alcançou o melhor desempenho global (precisão: 94%, IC 95%: 91-97%).

## **4. DISCUSSÃO**

### **4.1. Síntese dos Principais Achados**

Esta revisão sistemática fornece evidências robustas de que a IA representa uma ferramenta promissora para a detecção da DA via RM. Os achados demonstram que



técnicas de DL, especialmente CNNs, superam consistentemente métodos tradicionais de ML e aproximam-se da acurácia diagnóstica de especialistas humanos. A precisão global de 87% observada na meta-análise é comparável ou superior à relatada para avaliação clínica convencional (Beach et al., 2012).

O desempenho superior das técnicas de DL pode ser atribuído à sua capacidade de aprender representações hierárquicas complexas diretamente dos dados de imagem. A identificação automática de biomarcadores como atrofia hipocampal, alterações na rede de modo padrão e hiperintensidades da substância branca demonstra o potencial da IA para objetivar e quantificar alterações associadas à DA.

A emergência da IA Explicável representa um avanço crucial para a aceitação clínica dessas tecnologias. Técnicas como SHAP, Grad-CAM e LIME não apenas aumentam a confiança dos clínicos nas decisões dos modelos, mas também fornecem insights científicos valiosos sobre a fisiopatologia da DA.

## **4.2. Comparação com Literatura Existente**

Os resultados desta revisão são consistentes com meta-análises anteriores que demonstraram eficácia crescente da IA na análise de neuroimagem para DA (Bron et al., 2015; Tanveer et al., 2020). No entanto, esta revisão identifica melhorias significativas no desempenho diagnóstico nos últimos anos, refletindo avanços em algoritmos de DL e disponibilidade de conjuntos de dados maiores.

Comparado à revisão de Wen et al. (2020), que relatou precisão média de 81% para técnicas de ML, os estudos incluídos nesta revisão demonstram melhoria substancial, com precisão média de 87%. Esta melhoria pode ser atribuída ao maior uso de técnicas de DL e implementação de transfer learning.

## **4.3. Implicações Clínicas**

Os achados têm implicações importantes para a prática clínica. A capacidade da IA de detectar alterações precoces associadas à DA pode facilitar diagnóstico mais precoce e preciso, permitindo intervenções terapêuticas em estágios quando são potencialmente mais eficazes. Isto é particularmente relevante considerando o desenvolvimento de terapias modificadoras da doença (Cummings et al., 2023).



A objetivação e quantificação automática de biomarcadores de RM pode reduzir variabilidade inter-observador e melhorar reprodutibilidade diagnóstica. A capacidade de integrar múltiplas modalidades de RM e dados clínicos pode fornecer avaliações mais holísticas e personalizadas do risco de DA.

#### **4.4. Desafios e Limitações**

Apesar dos avanços promissores, vários desafios significativos permanecem. A “caixa-preta” dos algoritmos de DL continua sendo uma barreira importante, apesar dos avanços em XAI. A generalização dos modelos para populações diversas representa outro desafio crítico, com muitos conjuntos de dados sendo predominantemente compostos por indivíduos de origem europeia ou norte-americana.

Questões regulatórias e de responsabilidade legal também representam barreiras significativas. A aprovação de dispositivos médicos baseados em IA requer demonstração rigorosa de segurança e eficácia. A integração de sistemas de IA em fluxos de trabalho clínicos apresenta desafios técnicos e organizacionais.

#### **4.5. Direções Futuras**

Várias direções promissoras emergem para pesquisa futura. O desenvolvimento de modelos multimodais que integram dados de neuroimagem, biomarcadores líquidos, genética e avaliações clínicas pode fornecer avaliações mais abrangentes. A aplicação de técnicas de aprendizado federado pode permitir treinamento de modelos em conjuntos de dados distribuídos sem compartilhamento direto de dados.

O desenvolvimento de biomarcadores digitais baseados em IA pode facilitar monitoramento contínuo de pacientes e avaliação de resposta terapêutica. A integração de IA com outras tecnologias emergentes pode criar novas oportunidades para diagnóstico e intervenção.

#### **4.6. Limitações da Revisão**

Esta revisão apresenta várias limitações. A restrição a estudos Qualis A pode ter excluído estudos relevantes. A heterogeneidade metodológica entre os estudos limitou a capacidade de realizar meta-análises abrangentes. A qualidade variável dos estudos primários pode afetar a robustez das conclusões. A possibilidade de viés de publicação não pode ser completamente excluída.



## 5. CONCLUSÃO

Esta revisão sistemática fornece evidências robustas de que a Inteligência Artificial representa uma ferramenta promissora para a detecção da Doença de Alzheimer via Ressonância Magnética. As técnicas de Deep Learning, especialmente Redes Neurais Convolucionais, demonstraram desempenho superior comparado a métodos tradicionais, alcançando precisão diagnóstica de 87% na meta-análise realizada.

Os biomarcadores de RM identificados por algoritmos de IA demonstram potencial significativo para diagnóstico precoce e monitoramento da progressão da doença. A emergência da IA Explicável representa um avanço crucial para a aceitação clínica, fornecendo transparência necessária para confiança dos profissionais de saúde.

Apesar dos avanços promissores, desafios significativos permanecem para implementação clínica efetiva, incluindo questões de interpretabilidade, generalização para populações diversas, barreiras regulatórias e integração em fluxos de trabalho clínicos. A superação destes desafios requer colaboração multidisciplinar entre pesquisadores, clínicos, reguladores e desenvolvedores de tecnologia.

Direções futuras promissoras incluem desenvolvimento de modelos multimodais, aplicação de aprendizado federado e criação de biomarcadores digitais. Estudos multicêntricos prospectivos com validação externa robusta são essenciais para demonstrar eficácia clínica e facilitar aprovação regulatória.

Em conclusão, a IA na detecção da DA via RM está transitioning de uma promessa tecnológica para uma realidade clínica tangível. Com desenvolvimento contínuo e validação rigorosa, estas tecnologias têm potencial para transformar significativamente o diagnóstico e manejo da Doença de Alzheimer, oferecendo esperança para milhões de pacientes e famílias afetados por esta condição devastadora.

## 6. REFERÊNCIAS

ADADI, A.; BERRADA, M. Peeking inside the black-box: a survey on explainable artificial intelligence (XAI). **IEEE Access**, v. 6, p. 52138-52160, 2018.

ALZHEIMER'S DISEASE INTERNATIONAL. **World Alzheimer Report 2022**: Life after diagnosis:



navigating treatment, care and support. London: ADI, 2022.

BATTINENI, G. et al. Machine Learning Driven by MRI for Classification of Alzheimer Disease Progression. **JMIR Aging**, v. 7, e59370, 2024.

BEACH, T. G. et al. Accuracy of the clinical diagnosis of Alzheimer disease at National Institute on Aging Alzheimer Disease Centers, 2005-2010. **Journal of Neuropathology & Experimental Neurology**, v. 71, n. 4, p. 266-273, 2012.

BRON, E. E. et al. Standardized evaluation of algorithms for computer-aided diagnosis of dementia based on structural MRI: the CADDementia challenge. **NeuroImage**, v. 111, p. 562-579, 2015.

CHAMAKURI, S. et al. A systematic review on recent methods on deep learning for automatic detection of Alzheimer's disease. **Medicine in Novel Technology and Devices**, v. 20, p. 100285, 2024.

CUMMINGS, J. et al. Alzheimer's disease drug development pipeline: 2023. **Alzheimer's & Dementia: Translational Research & Clinical Interventions**, v. 9, n. 2, e12385, 2023.

EBRAHIMIGHAHNAVIEH, M. A.; LUO, S.; CHIONG, R. Deep learning to detect Alzheimer's disease from neuroimaging: A systematic literature review. **Computer Methods and Programs in Biomedicine**, v. 187, p. 105242, 2020.

FRISONI, G. B. et al. The clinical use of structural MRI in Alzheimer disease. **Nature Reviews Neurology**, v. 6, n. 2, p. 67-77, 2010.

FRIZZELL, T. O. et al. Artificial intelligence in brain MRI analysis of Alzheimer's disease over the past 12 years: A systematic review. **Ageing Research Reviews**, v. 77, p. 101614, 2022.

JACK JR, C. R. et al. NIA-AA Research Framework: Toward a biological definition of Alzheimer's disease. **Alzheimer's & Dementia**, v. 14, n. 4, p. 535-562, 2018.



KHOSROSHAHI, S. M. et al. Explainable Artificial Intelligence in Neuroimaging of Alzheimer's Disease: A Systematic Review. **Diagnostics**, v. 15, n. 2, p. 198, 2025.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. ImageNet classification with deep convolutional neural networks. **Communications of the ACM**, v. 60, n. 6, p. 84-90, 2017.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, n. 7553, p. 436-444, 2015.

LITJENS, G. et al. A survey on deep learning in medical image analysis. **Medical Image Analysis**, v. 42, p. 60-88, 2017.

MCKHANN, G. M. et al. The diagnosis of dementia due to Alzheimer's disease: recommendations from the National Institute on Aging-Alzheimer's Association workgroups on diagnostic guidelines for Alzheimer's disease. **Alzheimer's & Dementia**, v. 7, n. 3, p. 263-269, 2011.

PAGE, M. J. et al. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. **BMJ**, v. 372, n. 71, 2021.

PELLEGRINI, E. et al. Machine learning of neuroimaging for assisted diagnosis of cognitive impairment and dementia: A systematic review. **Alzheimer's & Dementia: Diagnosis, Assessment & Disease Monitoring**, v. 10, p. 519-535, 2018.

PRINCE, M. et al. **World Alzheimer Report 2015: The Global Impact of Dementia - An analysis of prevalence, incidence, cost and trends**. London: Alzheimer's Disease International, 2015.

RATHORE, S. et al. A review on neuroimaging-based classification studies and associated feature extraction methods for Alzheimer's disease and its prodromal stages. **NeuroImage**, v. 155, p. 530-548, 2017.

RUDIN, C. Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. **Nature Machine Intelligence**, v. n. 5, p. 206-215, 2019.



SCHULTENS, P. et al. Alzheimer's disease. **The Lancet**, v. 397, n. 10284, p. 1577-1590, 2021.

SHEA, B. J. et al. AMSTAR 2: a critical appraisal tool for systematic reviews that include randomised or non-randomised studies of healthcare interventions, or both. **BMJ**, v. 358, j4008, 2017.

TANVEER, M. et al. Machine learning techniques for the diagnosis of Alzheimer's disease: A review. **ACM Transactions on Multimedia Computing, Communications, and Applications**, v. 16, n. 1s, p. 1-35, 2020.

WARREN, S. L.; MOUSTAFA, A. A. Functional MRI, deep learning, and Alzheimer's disease: A systematic review. **Journal of Neuroimaging**, v. 33, n. 1, p. 5-18, 2023.

WEINER, M. W. et al. The Alzheimer's Disease Neuroimaging Initiative 3: Continued innovation for clinical trial improvement. **Alzheimer's & Dementia**, v. 13, n. 5, p. 561-571, 2017.

WEN, J. et al. Convolutional neural networks for classification of Alzheimer's disease: Overview and reproducible evaluation. **Medical Image Analysis**, v. 63, p. 101694, 2020.

WIMO, A. et al. The worldwide costs of dementia in 2019. **Alzheimer's & Dementia**, v. 19, n. 7, p. 2865-2873, 2023.