

AVANÇOS DA INTELIGÊNCIA ARTIFICIAL NA DETECÇÃO PRECOCE DA DEMÊNCIA: uma revisão sistemática

Tiago Queiroz Ferreira¹; Evaldo Cardoso Gomes²

RESUMO

Introdução: A demência constitui uma síndrome clínica caracterizada por declínio progressivo das funções cognitivas, incluindo comprometimento de memória, raciocínio e linguagem, acompanhado por alterações comportamentais e de personalidade. As áreas de *Machine Learning* e Inteligência Artificial vêm demonstrando crescimento exponencial em aplicações práticas. As técnicas de aprendizado computacional têm se mostrado particularmente relevantes por capacitarem sistemas automatizados a auxiliarem profissionais de saúde, aumentando a eficiência e precisão em processos diagnósticos. **Métodos:** Revisão sistemática com caráter qualitativo. A seleção dos artigos foi feita utilizando os descritores DeCS/MESH: Inteligência artificial; demência; biomarcadores; detecção. Foi utilizado o instrumento The PRISMA para contemplar as quatro etapas da revisão. **Resultados:** A busca resultou na seleção de 10 estudos relevantes que abordam a aplicação de modelos de inteligência artificial na detecção e análise da DA, com ênfase em imagens médicas (como OCT, ressonância magnética, PET e imagens da retina). **Discussão:** A extração de características (*features*) de imagens médicas e sua posterior utilização em modelos de aprendizado de máquina (ML) pode proporcionar um desempenho superior em comparação ao uso direto das imagens relacionadas a DA e outras demências. **Conclusão:** Há um crescimento significativo no número e na sofisticação dos estudos que utilizam IA para a detecção precoce da demência. No entanto, ainda encontra limitações metodológicas e técnicas nos estudos revisados. Em muitos casos, os modelos são treinados e validados em conjuntos de dados.

PALAVRAS-CHAVE: Aprendizado da máquina; Doença de Alzheimer; Imagens médicas.

ABSTRACT

Introduction: Dementia is a clinical syndrome characterized by the progressive decline of cognitive functions, including impairments in memory, reasoning, and language, accompanied by behavioral and personality changes. The fields of Machine Learning and Artificial Intelligence have shown exponential growth in practical applications. Computational learning techniques have proven particularly relevant as they enable automated systems to assist healthcare professionals, increasing efficiency and accuracy in diagnostic processes. **Methods:** Qualitative systematic review. The selection of articles was carried out using the DeCS/MESH descriptors: Artificial Intelligence; Dementia; Biomarkers; Detection. The PRISMA instrument was used to address the four stages of the review. **Results:** The search resulted in the selection of 10 relevant studies addressing the application of artificial intelligence models in the detection and analysis of AD, with an emphasis on medical imaging (such as OCT, magnetic resonance imaging, PET scans, and retinal images). **Discussion:** The extraction of features from medical images and their subsequent use in machine learning (ML) models can provide superior performance compared to the direct use of images related to AD and other dementias. **Conclusion:** There is significant growth in the number and sophistication of studies using AI for the early detection of dementia. However, methodological and technical limitations are still present in the reviewed studies. In many cases, the models are trained and validated on limited datasets.

Keywords: Machine learning; Alzheimer's disease; Medical imaging.

¹ Acadêmico de medicina do Centro Universitário Atenas, e-mail: tiagoqueiroz6@hotmail.com

² Professor, mestre e orientador no Centro Universitário Atenas

1 INTRODUÇÃO

A demência constitui uma síndrome clínica caracterizada por declínio progressivo das funções cognitivas, incluindo comprometimento de memória, raciocínio e linguagem, acompanhado por alterações comportamentais e de personalidade (Ministério da Saúde, 2023). Entre as doenças neurodegenerativas, o Alzheimer se destaca como a etiologia mais prevalente tanto no contexto brasileiro quanto global. Dados epidemiológicos da Organização Mundial da Saúde (OMS) revelam uma prevalência aproximada de 1,2 milhão de casos no Brasil e 50 milhões mundialmente, com incidência anual de cerca de 100 mil novos diagnósticos. Projeções indicam que esses números poderão dobrar até 2030 e triplicar até 2050 (Ministério da Saúde, 2023).

As áreas de Machine Learning e Inteligência Artificial vêm demonstrando crescimento exponencial em aplicações práticas. As técnicas de aprendizado computacional têm se mostrado particularmente relevantes por capacitarem sistemas automatizados a auxiliarem profissionais de saúde, aumentando a eficiência e precisão em processos diagnósticos (Data Science Academy, 2021).

Diante desse cenário, a OMS alerta para uma iminente crise global de saúde pública decorrente do aumento progressivo de casos de Alzheimer, destacando a urgência na implementação de abordagens tecnológicas inovadoras. O uso estratégico dessas ferramentas tem como objetivo principal aprimorar a capacidade de resposta do sistema de saúde, permitindo intervenções mais precoces e eficazes que possam mitigar os impactos devastadores da doença (Ministério da Saúde, 2023).

A Inteligência Artificial configura-se como um recurso tecnológico fundamental que está transformando os paradigmas de resolução de problemas e tomada de decisão (Maia et al., 2019). Essa relevância torna-se particularmente significativa no contexto do diagnóstico médico e da terapêutica de condições neurológicas complexas, caracterizadas por progressão gradual e sintomatologia altamente incapacitante. Neste cenário, a IA emerge como ferramenta capaz de processar dados complexos e detectar padrões sintomáticos sutis, frequentemente imperceptíveis aos pacientes e de difícil identificação pelos métodos convencionais.

Segundo Damasceno (2025), a capacidade analítica da IA no processamento de grandes volumes de informação possibilita não apenas maior acurácia diagnóstica, mas também a formulação de estratégias terapêuticas mais eficazes, oferecendo suporte decisivo aos profissionais de saúde. Na prática neurológica, a aplicação dessa tecnologia tem demonstrado avanços significativos, particularmente no refinamento de processos diagnósticos e terapêuticos, permitindo intervenções clínicas cada vez mais personalizadas.

O potencial da IA em identificar características patológicas específicas possibilita a adaptação precisa das condutas médicas às particularidades de cada caso clínico. Essa abordagem individualizada não apenas otimiza os resultados terapêuticos, como também promove melhoria significativa na qualidade de vida de pacientes com doenças neurológicas degenerativas, representando um avanço substancial no campo da medicina personalizada (Damasceno, 2025).

Com isso em mente, esse estudo tem por objetivo investigar o que os avanços da IA realmente apresentam quanto a essa possibilidade de auxiliar em diagnósticos de demência, principalmente diagnósticos precoces visando a melhoria da qualidade de vida dos sujeitos acometidos por essa condição.

2 MÉTODOS

A pesquisa a ser realizada será uma revisão sistemática com caráter qualitativo. Como descrito por De Lunetta & Guerra (2023), é um método de pesquisa que sintetiza evidências provenientes de estudos qualitativos sobre um tema específico, seguindo um protocolo rigoroso e transparente para minimizar vieses. Diferentemente das revisões sistemáticas tradicionais (que focam em dados quantitativos e meta-análises), essa abordagem busca interpretar padrões, significados e experiências relatados na literatura, utilizando técnicas de análise temática, síntese interpretativa ou teoria fundamentada.

Para elaboração dessa pesquisa, definiu-se a pergunta norteadora através da estratégia PICO. Sendo essa: população: sujeitos com comprometimento cognitivo leve (CCL) ou indivíduos assintomáticos com alto risco para demência; intervenção: triagem automatizada, identificação de biomarcadores imagens ou padrões preditivos em dados multimodais; comparação: avaliação clínica convencional (testes neuropsicológicos como MMSE, exames de imagem sem IA, ou critérios DSM-5) e outros métodos diagnósticos emergentes (ex.: biomarcadores líquidos); outcome: acurácia, sensibilidade e especificidade da IA na detecção precoce (ex.: diagnóstico confirmado em follow-up). Além da redução de custos, tempo para diagnóstico, aceitação clínica ou impacto na qualidade de vida.

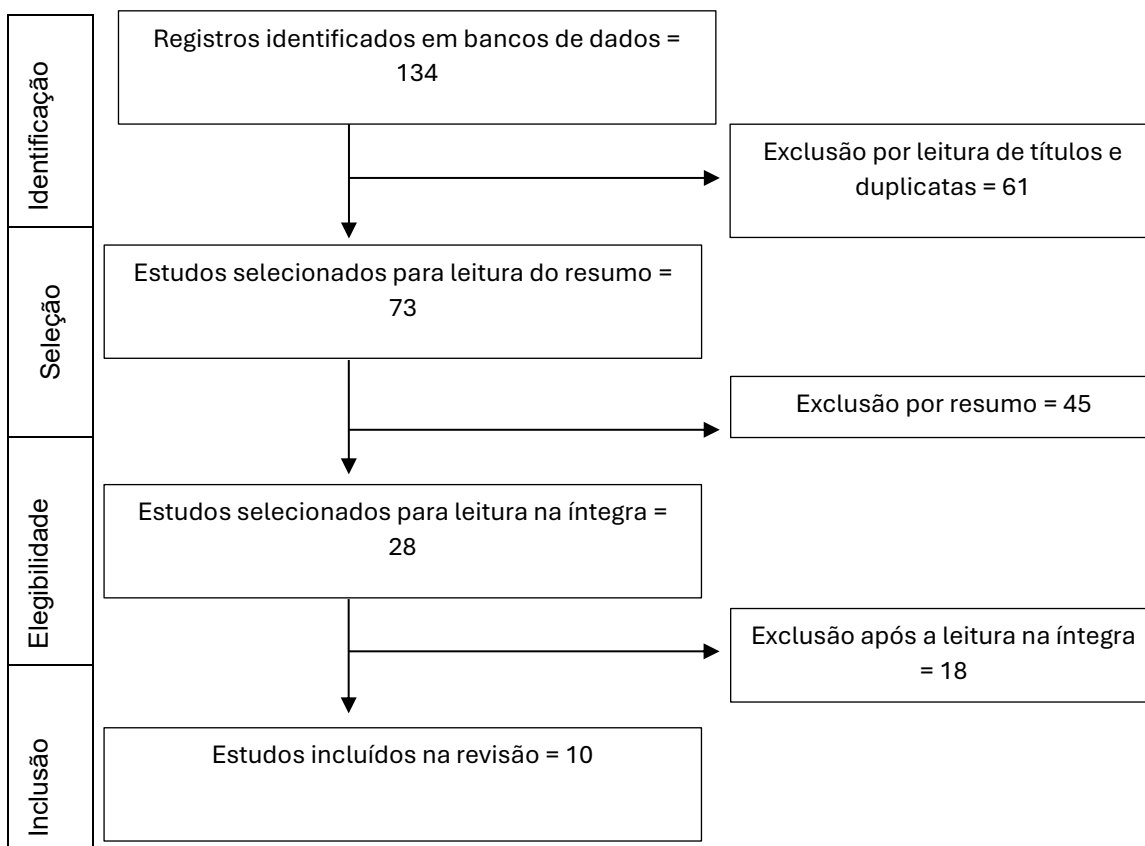
Com isso, a seleção dos artigos foi feita pelas bases de dados: SciELO, BVS e PubMed. Utilizando os descritores DeCS/MESH: Inteligência artificial; demência; biomarcadores; detecção.

Como critérios de inclusão, foram escolhidos artigos originais publicados de 2020 a 2025 os idiomas português, inglês e espanhol. E os de exclusão: teses, dissertações e estudos duplicados nas bases de dados.

Para coleta dos dados, o software Zotero foi empregado com o propósito de organizar, resumir e excluir duplicatas de estudos, levando em consideração: primeiro autor; ano, país, título, tipo de estudo e resultados principais.

Por fim, foi utilizado o instrumento The PRISMA 2020 statement: An updated guideline for reporting systematic reviews (Page et al., 2021) para contemplar as quatro etapas da revisão. Sendo o fluxograma PRISMA apresentado abaixo:

Figura 1: Cronograma PRISMA de seleção de artigos



3 RESULTADOS

AUTOR/ANO	TIPO DE ESTUDO	RESUMO
Uvaliyev et al., 2025	Observacional	Modelos baseados em SVM aplicados a imagens de OCT mostraram bons resultados na detecção da doença de Alzheimer, tanto em humanos quanto em modelos animais, com alta especificidade e acurácia.
Mohsen, 2025	Coorte Longitudinal	Modelos baseados em redes neurais profundas, especialmente CNNs, LSTMs e modelos híbridos, têm grande potencial na detecção da Doença de Alzheimer.
Jamshidiha et al., 2025	Observacional	O estudo comparou diferentes modelos de redes neurais convolucionais (CNNs) pré-treinados, incluindo EfficientNet-B3, MobileNet, ResNet-50, VGG-16 e o modelo fundacional RETFound, para detecção de retinopatia. Todos os modelos CNN foram inicializados com pesos treinados no ImageNet, enquanto o RETFound usou pesos treinados em imagens retiniais.
Liu et al., 2025	Estudo experimental	O estudo aplicou técnicas para lidar com o desequilíbrio de dados, como aumento de dados (com rotações de $\pm 20^\circ$ nas imagens da classe minoritária) e o uso de função de perda com pesos ajustados por classe. As imagens utilizadas (SVC, DVC e CC) passaram por transformação polar e espelhamento das imagens do olho esquerdo, aproveitando a simetria ocular.
Esmaeilzadeh et al., 2018	Coorte Longitudinal	O estudo propõe um método simples para identificar biomarcadores da Doença de Alzheimer em imagens de ressonância magnética, analisando a contribuição de diferentes regiões cerebrais para a classificação correta dos pacientes.
Hasan Saif; Al-Andoli; Bejuri, 2024	Meta-Análise	O estudo destaca a importância da Inteligência Artificial Explicável (XAI) para tornar os processos de decisão dos modelos de IA,

		especialmente em diagnósticos médicos como o da Doença de Alzheimer, mais transparentes e compreensíveis para médicos e usuários.
Wang et al., 2025	Coorte Longitudinal	O estudo propõe um modelo baseado em operadores neurais integrados a funções eigen de Laplace (LENO) para aprender diretamente a dinâmica espaço-temporal dos biomarcadores da Doença de Alzheimer (amiloide- β , tau e neurodegeneração) a partir de imagens PET clínicas.
Ming; Zhong; Juan, 2025	Estudo Observacional	O estudo realizou experimentos de hiperparâmetros para determinar a combinação ideal para o treinamento do modelo. Variando o número de épocas de treinamento, tamanhos de lote e dimensões das características, observaram que, com batch size 32 e dimensão de 100, a acurácia de classificação aumentava inicialmente com o número de épocas, mas depois diminuía.
Payan; Montana, 2015	Estudo experimental	Redes neurais convolucionais com convoluções 2D e 3D foram treinadas utilizando um conjunto de treinamento com 1.731 exemplos. Um conjunto de validação com 306 exemplos foi usado para determinar o momento ideal de parada antecipada (<i>early stopping</i>). Por fim, um conjunto de teste com 228 exemplos avaliou o desempenho do modelo em dados não vistos, gerando as métricas de performance reportadas.
Roy; Dorent; Burgos, 2025	Estudo experimental	A detecção de anomalias não supervisionada (UAD) é fundamental em neuroimagem para identificar desvios em relação a dados de indivíduos saudáveis, facilitando o diagnóstico de distúrbios neurológicos. Este trabalho foca em Bayesian Flow Networks (BFNs), uma nova classe de modelos generativos ainda não aplicada em imagens médicas ou detecção de anomalias.

A busca resultou na seleção de 10 estudos relevantes, publicados entre 2015 e 2025, que abordam a aplicação de modelos de inteligência artificial na detecção e análise da Doença de Alzheimer (DA), com ênfase em imagens médicas (como OCT, ressonância magnética, PET e imagens da retina).

Quanto ao tipo de estudo, observou-se uma diversidade metodológica:

- Estudos observacionais (n=3) investigaram o desempenho de modelos de IA em contextos clínicos ou com dados de imagem sem intervenções experimentais diretas;
- Estudos experimentais (n=3) focaram no desenvolvimento e avaliação técnica de modelos, com uso de conjuntos de treino, validação e teste;
- Estudos de coorte longitudinal (n=3) acompanharam pacientes ao longo do tempo para avaliar a progressão da doença e a acurácia preditiva dos modelos;
- Uma meta-análise (n=1) discutiu aspectos teóricos e práticos da Inteligência Artificial Explicável (XAI) no contexto da DA.

Em relação aos métodos e abordagens utilizadas, os estudos incluíram:

- Modelos baseados em redes neurais profundas, como CNNs, LSTMs e Transformers;
- Técnicas para ajuste de hiperparâmetros e tratamento de desequilíbrio de dados;
- Aplicações de aprendizado supervisionado e não supervisionado, como o uso de redes generativas para detecção de anomalias;
- Estratégias de transferência de aprendizado e uso de pesos pré-treinados em datasets como ImageNet ou imagens retiniais;
- Propostas inovadoras como o uso de operadores neurais com funções de Laplace (LENO) e redes Bayesian Flow Networks (BFNs).

Os modelos foram testados com diferentes bases de dados e técnicas de validação, como early stopping, avaliação por folds e divisão entre conjuntos de treino, validação e teste. De forma geral, os estudos reportaram alta acurácia e especificidade, com resultados promissores para a detecção precoce e acompanhamento da progressão da Doença de Alzheimer.

4 DISCUSSÃO

Modelo atual de detecção de demência

Atualmente, a detecção da demência é predominantemente clínica e depende de uma combinação de avaliação médica, exames laboratoriais e neuropsicológicos. O processo inicia-se geralmente com a observação de sinais e sintomas cognitivos, comportamentais ou funcionais pelo próprio paciente ou familiares, como perda de memória, desorientação, dificuldades de linguagem e alterações de humor. O médico realiza então uma anamnese detalhada, buscando identificar histórico médico, uso de medicamentos, presença de comorbidades e possíveis fatores de risco, como hipertensão, diabetes e histórico familiar de doenças neurodegenerativas (Maia et al., 2019).

Além da avaliação clínica, o diagnóstico de demência frequentemente envolve testes neuropsicológicos padronizados que avaliam funções cognitivas específicas, como atenção, memória,

linguagem, habilidades visuoespaciais e funções executivas. Entre os instrumentos mais utilizados estão o Mini Exame do Estado Mental (MEEM), a Escala de Avaliação da Demência de Clinical Dementia Rating (CDR) e o Teste do Desenho do Relógio. Esses testes permitem quantificar o comprometimento cognitivo e acompanhar a progressão da doença, porém dependem significativamente da experiência do profissional e da cooperação do paciente, o que pode introduzir variabilidade nos resultados (Mohsen, 2025).

Exames de imagem, como ressonância magnética (RM) e tomografia computadorizada (TC), também são ferramentas importantes na detecção da demência, auxiliando na identificação de atrofia cerebral, alterações estruturais e exclusão de outras condições que possam mimetizar o quadro demencial, como tumores ou acidentes vasculares cerebrais. Exames laboratoriais podem ser solicitados para investigar causas secundárias de declínio cognitivo, incluindo deficiências vitamínicas, distúrbios hormonais e infecções. Apesar de sua relevância, esses métodos tradicionais apresentam limitações na detecção precoce da doença, muitas vezes identificando alterações apenas em estágios moderados, quando já há comprometimento funcional significativo (Maia et al., 2019).

Dispositivos de detecção

A detecção da demência conta com uma série de dispositivos e ferramentas tradicionais que auxiliam na avaliação clínica e cognitiva. Entre os mais utilizados estão os equipamentos de neuroimagem, como a RM e a TC, que permitem observar alterações estruturais no cérebro, como atrofia em regiões específicas associadas à memória e ao raciocínio, como o hipocampo. Além disso, exames de imagem funcional, como a tomografia por emissão de pósitrons (PET), possibilitam avaliar o metabolismo cerebral e identificar padrões de comprometimento característicos de diferentes tipos de demência. Esses dispositivos são fundamentais para complementar o diagnóstico clínico, embora dependam de interpretação especializada e apresentem limitações na detecção precoce, especialmente em estágios iniciais da doença (Mohsen, 2025).

Outros dispositivos incluem equipamentos usados em testes neuropsicológicos e avaliações cognitivas padronizadas. Tablets e computadores já são empregados para aplicar baterias de testes de memória, atenção e funções executivas, possibilitando registro automático dos resultados. Além disso, dispositivos de monitoramento domiciliar, como sensores de movimento e wearables, têm sido utilizados para rastrear mudanças comportamentais e padrões de sono, que podem indicar comprometimento cognitivo. Embora auxiliem na detecção de alterações sutis, esses métodos ainda requerem interpretação humana e não são totalmente capazes de identificar a demência em seus estágios mais precoces com alta precisão (Wang et al., 2025).

Com a evolução da inteligência artificial, novos dispositivos vêm sendo desenvolvidos para detectar sinais precoces de demência de maneira mais sensível e automatizada. Ferramentas baseadas em IA podem analisar imagens de neuroimagem com algoritmos de aprendizado profundo, identificando padrões de atrofia cerebral que passam despercebidos ao olho humano. Esses sistemas são capazes de comparar milhões de dados de referência para detectar alterações sutis, potencialmente permitindo diagnósticos em estágios iniciais, quando intervenções terapêuticas podem ser mais eficazes (Uvaliyev et al., 2025).

Além disso, dispositivos de monitoramento digital, como aplicativos para smartphones, wearables e sensores domiciliares, estão sendo integrados a algoritmos de IA para analisar padrões de fala, escrita, mobilidade, sono e atividades diárias. Esses sistemas conseguem detectar pequenas alterações comportamentais e cognitivas ao longo do tempo, oferecendo um rastreamento contínuo e personalizado. O uso da IA nesses dispositivos não substitui a avaliação clínica, mas complementa o diagnóstico tradicional, fornecendo insights que podem antecipar a detecção da demência e auxiliar na tomada de decisões médicas mais precisas (Wang et al., 2025).

A IA em detecção de demência

A extração de características (features) de imagens médicas e sua posterior utilização em modelos de aprendizado de máquina (ML) pode proporcionar um desempenho superior em comparação ao uso direto das imagens relacionadas a DA e outras demências. Tal constatação reforça a relevância dos modelos de ML na detecção de DA, especialmente quando se consideram aspectos como a interpretabilidade e a capacidade de generalização (Uvaliyev et al., 2025).

Um exemplo claro é o estudo de Mohsen (2025), no qual características extraídas da área da zona avascular foveal (FAZ) utilizando de modelos ML resultaram em desempenho superior que operavam diretamente com as imagens. Isso destaca o potencial dos modelos baseados em atributos específicos, especialmente em contextos clínicos, onde a transparência do processo de decisão é essencial.

Entretanto, diversos desafios precisam ser enfrentados para que modelos de ML atinjam seu pleno potencial. Um dos principais obstáculos é a seleção adequada de características relevantes, processo que pode exigir tanto conhecimento médico especializado quanto o uso de técnicas computacionais de pré-processamento (Jamshidiha et al., 2025; Uvaliyev et al., 2025).

Estratégias como o uso da matriz de coocorrência de níveis de cinza, como proposto em Esmaeilzadeh et al. (2018), demonstraram ser eficazes na identificação de padrões relevantes para a classificação. Contudo, a presença de características redundantes ou irrelevantes pode comprometer o desempenho do modelo, tornando fundamental o emprego de técnicas de seleção de atributos e redução de dimensionalidade, como a análise de componentes principais (PCA).

Além disso, a avaliação confiável do desempenho dos modelos requer o uso de conjuntos de dados independentes para teste. Muitos estudos, como Jamshidiha et al. (2025) e Liu et al. (2025) ainda validam seus modelos apenas com os dados de treinamento, o que limita a capacidade de generalização e pode inflar artificialmente os resultados.

Outro fator limitante recorrente é o desequilíbrio entre classes nos bancos de dados, o que tende a favorecer a classe majoritária durante o treinamento. Nesse sentido, técnicas como o SMOTE (Synthetic Minority Over-sampling Technique) podem ser úteis para aumentar a representatividade das classes minoritárias e melhorar o desempenho global do modelo (Liu et al., 2025).

A utilização de dados multimodais de neuroimagem tem se mostrado uma abordagem promissora para a identificação de biomarcadores estruturais e funcionais associados à DA. (Hasan Saif; Al-Andoli; Bejuri, 2024).

Em particular, medidas volumétricas ou de espessura cortical em regiões cerebrais pré-determinadas, como o hipocampo e o córtex entorrinal, áreas sabidamente afetadas nos estágios iniciais da DA, vêm sendo amplamente empregadas como atributos relevantes em modelos de aprendizado de máquina. Essa seleção dirigida de características pode melhorar substancialmente a acurácia dos modelos preditivos, fornecendo uma base sólida para a construção de classificadores mais robustos (Wang et al., 2025).

Nos últimos anos, métodos híbridos que integram aprendizado profundo (deep learning) e aprendizado tradicional (como SVM) têm ganhado destaque, sobretudo por sua capacidade de extrair automaticamente representações de alto nível dos dados de neuroimagem. Conforme evidenciado nesta revisão, quatro estudos utilizaram esse tipo de abordagem combinada, geralmente empregando redes profundas, como autoencoders empilhados (SAE), para realizar a seleção e transformação de características, e classificadores SVM multikernel para realizar a etapa de classificação. Tais métodos demonstraram desempenho expressivo, como observado no estudo de Ming; Zhong; Juan (2025), que alcançou 95,9% de acurácia na classificação entre indivíduos com DA e controles cognitivos normais (CN), além de 75,8% de acurácia na predição da conversão de MCI (comprometimento cognitivo leve) para DA.

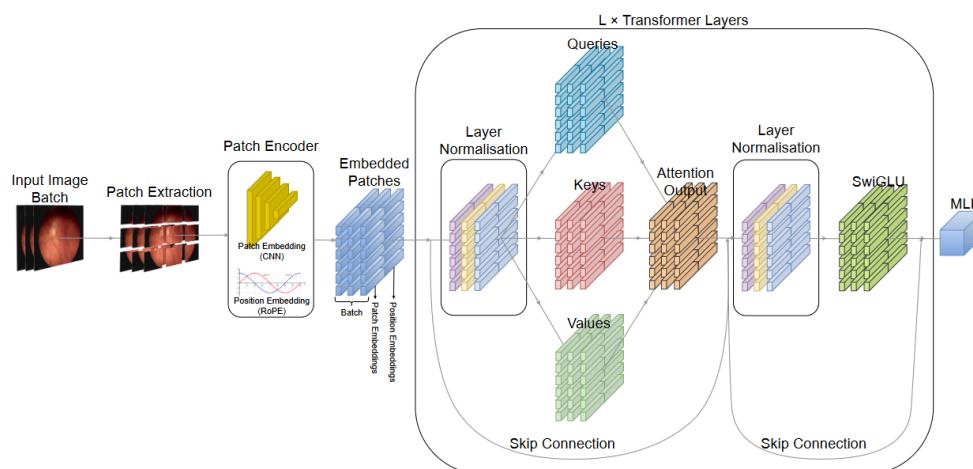
Apesar do bom desempenho geral, os resultados também apontam limitações importantes dos modelos baseados exclusivamente em redes profundas como classificadores. No estudo subsequente dos mesmos autores (Payan; Montana, 2015), o uso do SAE como classificador resultou em desempenho inferior, com acurácia de 89,9% para AD/CN e apenas 60,2% para a conversão de MCI para DA. Esse achado reforça a hipótese de que a combinação entre redes profundas para extração de atributos e classificadores

tradicionais, como o SVM, pode oferecer melhor equilíbrio entre capacidade de representação e generalização do modelo. Abordagens mais sofisticadas, como a inicialização de parâmetros com amostras não relacionadas à tarefa e o ajuste fino com dados específicos, também foram testadas, atingindo índices notáveis, como 98,8% de acurácia para classificação AD/CN e 83,7% para predição de conversão MCI-AD (Payan; Montana, 2015).

Além disso, técnicas como o uso de Restricted Boltzmann Machines (RBM) com dropout foram exploradas para reduzir o overfitting e aprimorar a generalização dos modelos, ainda que com desempenho ligeiramente inferior em algumas métricas. O estudo de Roy; Dorent; Burgos (2025), por exemplo, obteve 91,4% de acurácia para AD/CN, mas apenas 57,4% para a predição de MCI para DA, evidenciando a complexidade da tarefa preditiva e a necessidade de abordagens que consigam lidar com a heterogeneidade dos dados e os diferentes estágios da doença.

A escassez de dados clínicos de qualidade é um dos principais desafios enfrentados na construção de modelos robustos de aprendizado profundo voltados à classificação de imagens médicas. A principal limitação observada por Jamshidiha et al. (2025), foi o tamanho reduzido do conjunto TRENDv2 apresentado na Figura 2, que motivou o uso de imagens de indivíduos saudáveis (HCs) para aumentar o volume de dados, resultando, no entanto, em um dataset altamente desbalanceado, com apenas 14% das imagens referentes a pacientes com DA. Para mitigar esse desbalanço e evitar vieses no treinamento, foi aplicada a técnica de oversampling da classe minoritária apenas no subconjunto de treinamento, dentro de um esquema de validação cruzada aninhada (Jamshidiha et al., 2025).

Figura 2: Modelo explicativo de aprendizado da máquina.



Fonte: Jamshidiha et al., 2025.

Além do desafio do desbalanceamento, a natureza tridimensional das imagens de OCT exigiu uma etapa prévia de conversão para fatias bidimensionais, com o objetivo de facilitar a visualização e a explicabilidade dos modelos. Todas as imagens foram redimensionadas para 50x50 pixels e normalizadas para o intervalo [0, 1], mantendo o pré-processamento ao mínimo necessário. Importante destacar que, no caso das imagens de OCT, o conjunto de dados já era balanceado, dispensando assim o uso de técnicas adicionais de ajuste da distribuição de classes.

A proposta de detecção de demências ou Alzheimer por meio de imagens auxiliadas por IA's representa um avanço metodológico ao expandir o arcabouço original das BFNs para reconstruções pseudo-saudáveis que preservam a identidade do sujeito, superando abordagens existentes em termos de precisão na identificação de alterações simuladas compatíveis com a Doença de Alzheimer (Roy; Dorent; Burgos, 2025).

Essa abordagem permite que os modelos não apenas detectem regiões de anomalia com alta precisão, mas também mantenha a coerência anatômica e o realismo das reconstruções, atributos fundamentais para aplicação clínica. Além disso, o uso de IA's como estratégia de detecção favorece a interpretabilidade dos resultados, o que é particularmente relevante no contexto de diagnóstico assistido por IA (Ming; Zhong; Juan, 2025).

Apesar dos avanços apresentados, devemos apontar a necessidade de aprimorar a robustez da detecção de anomalias por meio da Inteligência Artificial, uma vez que o campo ainda se encontra em desenvolvimento, mesmo que com resultados promissores (Hasan Saif; Al-Andoli; Bejuri, 2024).

Nesse sentido, Liu et al. (2025) propõe como perspectivas futuras a investigação de diferentes estratégias de escalonamento de acurácia, bem como a aplicação de diferentes metodologias em conjuntos de dados variados, abrangendo múltiplas modalidades de imagem e diferentes condições patológicas. Essa ampliação permitiria uma avaliação mais abrangente da capacidade de generalização do modelo e sua aplicabilidade em contextos clínicos heterogêneos.

5 CONCLUSÃO

O trabalho apresentado teve como objetivo investigar se modelos de IA apresentam possibilidades concretas e futuras para a detecção precoce de modelos de demência. Partiu-se da hipótese de que a IA, ao empregar algoritmos de aprendizado de máquina, redes neurais profundas e técnicas avançadas de análise de dados, pode identificar padrões clínicos e neurobiológicos sutis que precedem o diagnóstico convencional, promovendo, assim, uma mudança de paradigma nos métodos diagnósticos da demência.

Os resultados analisados confirmam que há um crescimento significativo no número e na sofisticação dos estudos que utilizam IA para a detecção precoce da demência, especialmente nos últimos anos. Os modelos aplicados a exames de neuroimagem, como ressonância magnética (RM) e tomografia por emissão de pósitrons (PET), têm demonstrado capacidades de classificação superiores às abordagens tradicionais, muitas vezes com alta acurácia, sensibilidade e especificidade. Além disso, algoritmos capazes de processar dados clínicos e neuropsicológicos têm se mostrado eficazes na previsão de conversão de comprometimento cognitivo leve (CCL) para demência, revelando-se ferramentas promissoras na prática clínica.

No entanto, a hipótese de que a IA já transformou de maneira consolidada a detecção precoce da demência ainda encontra limitações metodológicas e técnicas nos estudos revisados. Em muitos casos, os modelos são treinados e validados em conjuntos de dados reduzidos ou homogêneos, o que compromete a generalização dos resultados para contextos clínicos mais amplos. Além disso, a escassez de validação externa, a falta de padronização nos protocolos de imagem e a baixa explicabilidade de alguns modelos dificultam sua implementação em larga escala nos sistemas de saúde.

Mesmo com esses desafios, os achados sustentam a premissa de que a IA possui um grande potencial de impacto no campo da neurologia e da geriatria, particularmente na detecção precoce da demência. Com o amadurecimento tecnológico, espera-se que futuras aplicações superem as limitações atuais, promovendo diagnósticos mais rápidos, acessíveis e precisos. A integração de sistemas inteligentes aos fluxos de cuidado poderá não apenas antecipar o diagnóstico, mas também permitir intervenções terapêuticas mais eficazes em estágios iniciais da doença, com benefícios diretos à qualidade de vida dos pacientes e à gestão dos serviços de saúde.

Então, é possível dizer que embora o campo ainda esteja em desenvolvimento, a IA representa uma fronteira promissora para a medicina preventiva em saúde mental e neurodegenerativa. A continuidade das

pesquisas, especialmente aquelas com foco em validação multicêntrica, explicabilidade e aplicabilidade clínica, será fundamental para consolidar o papel da IA como aliada estratégica na luta contra a demência.

REFERÊNCIAS BIBLIOGRÁFICAS

BRASIL. Ministério da Saúde. Ministério da Saúde (ed.). **Doença de Alzheimer**. 2023. Disponível em: <https://www.gov.br/saude/pt-br/assuntos/saude-de-a-az/a/alzheimer>. Acesso em: 05 mar. 2023.

DAMASCENO, Evelyn Ravena Rodrigues. **O uso da Inteligência Artificial no tratamento de pacientes com danos neurológicos severos**: uma revisão integrativa de literatura. *Brazilian Journal of Development*, v. 11, n. 2, p. e77608-e77608, 2025.

DATA SCIENCE ACADEMY (Brasil). **Deep Learning Book**: em português, online e gratuito. São Paulo: Deep Learning Book, 2021. 100 v. Disponível em: <https://www.deeplearningbook.com.br/>. Acesso em: 05 fev. 2023.

DE LUNETTA, Avaetê; GUERRA, Rodrigues. **Metodologia da pesquisa científica e acadêmica**. *Revista OWL (OWL Journal)-Revista Interdisciplinar de Ensino e Educação*, v. 1, n. 2, p. 149-159, 2023.

ESMAEILZADEH, Soheil et al. **End-to-end Alzheimer's disease diagnosis and biomarker identification**. In: *International workshop on machine Learning in medical imaging*. Cham: Springer International Publishing, 2018. p. 337-345.

HASAN SAIF, Fatima; AL-ANDOLI, Mohamed Nasser; BEJURI, Wan Mohd Yaakob Wan. **Explainable AI for Alzheimer detection**: A review of current methods and applications. *Applied Sciences*, v. 14, n. 22, p. 10121, 2024.

JAMSHIDIHA, Saeed et al. **An Explainable Transformer Model for Alzheimer's Disease Detection Using Retinal Imaging**. arXiv preprint arXiv:2507.04259, 2025.

LIU, Shouyue et al. **Beyond the eye**: A relational model for early dementia detection using retinal OCTA images. *Medical Image Analysis*, v. 102, p. 103513, 2025.

MAIA, Mayanne C. et al. **Inteligência artificial para o apoio ao diagnóstico da doença de Alzheimer utilizando imagens de ressonância magnética**. *Anais do III Simpósio de Inovação em Engenharia Biomédica-SABIO 2019*, p. 47, 2019.

MING, Yang; ZHONG, Jiang Shi; JUAN, Zhou Su. **Multi-omic Prognosis of Alzheimer's Disease with Asymmetric Cross-Modal Cross-Attention Network**. arXiv preprint arXiv:2507.08855, 2025.

MOHSEN, Saeed. **Alzheimer's disease detection using deep learning and machine learning**: a review. *Artificial Intelligence Review*, v. 58, n. 9, p. 262, 2025.

PAGE, Matthew J. et al. **The PRISMA 2020 statement**: an updated guideline for reporting systematic reviews. *bmj*, v. 372, 2021.

PAYAN, Adrien; MONTANA, Giovanni. **Predicting Alzheimer's disease**: a neuroimaging study with 3D convolutional neural networks. arXiv preprint arXiv: 1502.02506. 2015.

ROY, Hugues; DORENT, Reuben; BURGOS, Ninon. **Unsupervised anomaly detection using Bayesian flow networks**: application to brain FDG PET in the context of Alzheimer's disease. arXiv preprint arXiv: 2507.17486. 2025.

UVALIYEV, Adilet; CHAN, Leanne Lai Hang. **Alzheimer's Disease Detection from Retinal Images Using Machine Learning and Deep Learning Techniques: A Perspective**. Applied Sciences, v. 15, n. 9, p. 4963, 2025.

WANG, Jindong et al. **Learning Patient-Specific Spatial Biomarker Dynamics via Operator Learning for Alzheimer's Disease Progression**. arXiv preprint arXiv: 2507.16148, 2025.