

FACULDADE DE TECNOLOGIA DE SÃO PAULO

Gabrielly de Lima Baião

A importância da inteligência artificial e *machine learning* (aprendizado de máquina) na avaliação por ressonância magnética da doença de Alzheimer

São Paulo

2025

Gabrielly de Lima Baião

A importância da inteligência artificial e *machine learning* (aprendizado de máquina) na avaliação por ressonância magnética da doença de Alzheimer

Trabalho de conclusão de curso submetido como exigência parcial para a obtenção do grau de Tecnólogo em Análise e Desenvolvimento de Sistemas.

Orientador: Prof. Dr. Maurício Amaral de Almeida

São Paulo

2025

RESUMO

Objetivo: O objetivo deste trabalho foi revisar sistematicamente a importância da inteligência artificial, deep learning, aprendizado de máquina e redes neurais na avaliação da doença de Alzheimer por ressonância magnética e demonstrar como são capazes de verificar com precisão cérebros saudáveis com cognição normal de cérebros com alterações causadas pela doença de Alzheimer. **Métodos:** Efetuou-se uma pesquisa na *ACM Digital Library* (ACM), *IEEE Xplore Digital Library* (IEEE) e *Pubmed* no período de 2015 a 2020, utilizando-se as seguintes palavras chaves: “*Artificial intelligence*”, “*MRI*”, “*Alzheimer*”, “*Neural networks*”, “*Machine learning*” , além de referências cruzadas dos artigos selecionados. **Resultados:** Foram encontrados 20 estudos que preencheram os critérios de inclusão adotados para o presente trabalho. Estes estudos mostraram que é possível obter a melhor evidência quanto ao aprendizado de máquina e seu modo de avaliação em pacientes com Alzheimer. **Conclusão:** Verificou-se que a produção científica mundial sobre inteligência artificial e aprendizado de máquina tem ganhado cada vez mais relevância com estudos importantes que predizem o diagnóstico individual e o comprometimento cognitivo leve com base na ressonância magnética.

Descritores: Doença de Alzheimer; Inteligência artificial; Ressonância magnética; Redes Neurais; Aprendizado de Máquina.

ABSTRACT

Purpose: *The aim of this article was to systematically review the importance of artificial intelligence, deep learning, machine learning and neural networks in the evaluation of Alzheimer's disease by magnetic resonance imaging.* **Methods:** *Performed a search in ACM Digital Library (ACM), IEE Xplore Digital Library (IEEE) and Pubmed in the period from 2015 to 2020, using the following keywords: "Artificial intelligence", "MRI", "Alzheimer", "Neural networks", "Machine learning", ins addition to cross-references of the selected articles.* **Results:** *Twenty studies were found that met the inclusion criteria adopted for the present study. These studies show that it's possible to obtain the best proof of machine learning and it's way of evaluating Alzheimer's patients.* **Conclusion:** *It was found that the worldwide scientific production on artificial intelligence and machine learning are increasingly relevant with important studies on individual diagnosis and mild cognitive impairment based on magnetic resonance imaging.*

Key words: Alzheimer's disease; Artificial Intelligence, MRI, Neural Networks, Deep learning.

SUMÁRIO

INTRODUÇÃO.....	6
MÉTODO.....	8
RESULTADOS.....	9
DISCUSSÃO.....	16
CONCLUSÃO.....	17
REFERÊNCIAS.....	18

Introdução

A demência por doença de Alzheimer (DA) é um dos tipos de desordem psicológica que mais acometem a população mundial. É uma síndrome lenta e progressiva caracterizada por diversos problemas cognitivos que incluem dificuldades na memória, função executiva, atenção, linguagem e habilidades viso espaciais⁽¹⁾.

Não há ocorrências fixas que possam definir o início da doença, por isso, que há grande dificuldade da equipe médica em diagnosticar com precisão a demência por Alzheimer devido a sua individualidade⁽²⁾.

Segundo a *Alzheimer's Association* a DA em comparação com o câncer de mama e o câncer de próstata combinados, ocupa a sexta posição como principal causa de morte nos Estados Unidos⁽³⁾, já no Brasil é responsável por 50% a 60% dos casos em pessoas acima de 60 anos⁽⁴⁾.

Há falta de informações sobre o crescimento da DA no Brasil, mas, conforme alguns estudos estima-se que existam cerca de 55.000 novos casos por ano, correspondendo a 7% da população idosa afetada⁽⁵⁾. A DA tem aumentado os custos com a saúde, só nos EUA e Europa são gastos 2 trilhões de dólares anualmente⁽⁶⁾.

A neuropatologia da doença compara características clínicas com informação genética⁽⁷⁾, por exemplo, até mesmo o gene da trissomia, característica da síndrome de down pode levar a ocorrência prematura da doença de Alzheimer, ao mesmo tempo agregados da proteína tau hiperfosforilada são capazes de perturbar a disposição dos microtúbulos e difundir a deposição da proteína β -amilóide extracelular ($A\beta$)⁽⁸⁾. Podem ocorrer mudanças características como a perda de terminais sinápticos, o que pode levar a redução da função cognitiva, pode-se entender que a perda de sinapses é o ponto chave para a decadência do processo cognitivo no período inicial da doença⁽⁹⁾.

Os biomarcadores são importantes para a investigação, pois estudos clínicos indicam que o diagnóstico da doença é imprecisa mesmo entre os pesquisadores mais experientes em cerca de 10% a 15% dos casos há diagnósticos incorretos. Os biomarcadores podem servir indiretamente para mensurar a gravidade da doença⁽¹⁰⁾.

Temos como biomarcadores de imagem a utilização de ressonância magnética volumétrica e tomografia por emissão de pósitrons, que avaliam a utilização de glicose ou ligação de ligantes à placa amiloide. Um dos principais biomarcadores para a doença é o nível de proteínas $A\beta$ e tau do líquido cefalorraquidiano⁽¹¹⁾.

O biomarcador citado utiliza métodos invasivos, por isso, que é tão necessário utilizar técnicas de imagem como a Ressonância Magnética (RM) ou tomografia por emissão de pósitrons (PET), pois podem detectar de forma precoce a DA⁽²⁾. Há indícios, de que o patomecanismo molecular da doença estão ativos anos antes do início da morte neuronal e os problemas cognitivos comecem a se manifestar⁽¹²⁾.

Obteríamos um tratamento eficaz a partir da detecção dessa fase, pois a função cognitiva seria preservada. Por isso, com a expectativa de que a imagem possa proporcionar maior sensibilidade e especificidade, baseando-se em dados estruturais de ressonância magnética a partir de algumas amostras do conjunto de treinamento do desafio de diagnóstico de demência auxiliado por computador (CADDementia)⁽¹³⁾, são demonstrados na Figura 1, onde podemos notar em (b) atrofia em estruturas temporais como hipocampo e em regiões posteriores do córtex parietal.



(a) Cognitively normal (*train_vumc_007*).



(b) Alzheimer's disease (*train_emc_009*).

Figura 1. Nos planos Coronal, sagital e axial de indivíduos cognitivamente normais e acometidos pela Doença de Alzheimer do conjunto de treinamento CADDementia⁽²⁾.

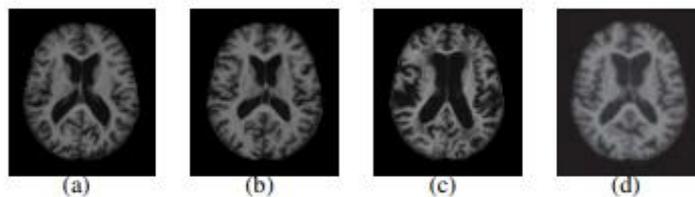


Figura 2. Exemplo de diferentes estágios da DA em imagens de RM cerebrais. Em (a) sem alteração; (b) demência muito leve; (c) demência leve; (d) demência moderada⁽¹⁴⁾.

A Figura 2 demonstra algumas imagens de RM com alterações cerebrais em diferentes estágios. Nota-se que em seu desenvolvimento mais avançado ocorrem danos no tecido cerebral, marcados por encolhimento do córtex cerebral e hipocampo, bem como aumento dos ventrículos laterais.

Pensando em como ter diagnósticos mais precisos, algumas pesquisas tem demonstrado que o uso de *machine learning* (aprendizado de máquina) que é uma aplicação de análise de dados com a capacidade de criar algoritmos que podem aprender a partir de dados que lhe são apresentados está em crescente uso.

Os algoritmos podem ser criados para realizar a varredura e identificar possíveis pontos de identificação da patologia e redefinir o protocolo. Já o método de aprendizagem profunda (*deep learning*) é inovador ao se comparar com métodos tradicionais de *machine learning*, pois podem desenvolver padrões de redes neurais de modo direto das imagens por RM sem ou com a intervenção mínima de um especialista humano. As redes neurais convolucionais atingiram uma alta precisão em classificações de padrões usando imagens digitais, sobretudo em aplicações de sistemas CAD (Computed Aided Diagnosis – Diagnóstico Assistido por Computador) que será de vital importância para os profissionais médicos ⁽¹⁵⁾.

No campo da neurologia a inteligência artificial é capaz de auxiliar em diversos problemas, por isso, o objetivo deste trabalho é revisar sistematicamente a importância da inteligência artificial, deep learning, aprendizado de máquina e redes neurais na avaliação da doença de Alzheimer por ressonância magnética e demonstrar como são capazes de verificar com precisão cérebros saudáveis com cognição normal de cérebros com alterações causadas pela DA.

Métodos

O planejamento dessa revisão sistemática teve como objetivo inicial levantar o uso de inteligência artificial que hoje em dia envolve o uso de redes neurais e, ou *deep learning*, e as imagens de RMN seriam a aplicação dos desenvolvimentos de trabalhos nessa linha com relação a avaliação da doença de Alzheimer.

Neste contexto, uma investigação detalhada foi previamente introduzida em diversas bases científicas. A escolha das fontes de consulta tiveram como base as palavras chaves

utilizadas na revisão sistemática. Portanto, foram selecionadas as bases de dados que publicam artigos relacionados ao tema:

- ACM Digital Library (ACM)
- IEE Xplore Digital Library (IEEE)
- Pubmed

Foram combinados termos de pesquisa, sendo a consulta exata: “*Artificial intelligence and MRI and Alzheimer and Neural networks and Machine learning*” . Ao todo, foram encontrados 91 artigos. A busca foi realizada em fevereiro de 2025 e a seleção dos artigos levaram em conta critérios de inclusão e exclusão.

Os critérios para elegibilidade foram: 1) Seleção a partir da leitura do título dos artigos; 2) Leitura do resumo / abstract ser coerente com o tema em estudo ; 3) Os artigos selecionados a partir da leitura do resumo / abstract foram incluídos para a leitura na íntegra, onde foi feita uma leitura detalhada em busca de informações que se relacionassem aos objetivos desta revisão sistemática; 4) Todos os artigos selecionados para uma leitura na íntegra foram incluídos neste estudo.

Os critérios de exclusão foram: 1) Artigos escritos em outros idiomas, senão o inglês ou português; 2) O ano de publicação não estar entre 2015 e ao fim dessa revisão; 3) Ser similar em conteúdo e resultados; 4) Não estar disponível nas bases de dados consultadas ou em outros meios.

Todos os aspectos de interesse para a realização desta revisão sistemática foram coletadas a partir dos artigos que seguiram o critério de elegibilidade e foram tabelados em uma base de dados feita especificamente para este estudo: Referências; Anomalias; Modalidade de imagem; Interesses ; Métodos de avaliação; Nível de precisão do modelo. Através do *software Microsoft Office Excel 2010* o armazenamento dos dados foi realizado.

Ao considerar os critérios para elegibilidade e exclusão, o número total de documentos identificados foi 91. Após a leitura na íntegra dos artigos selecionados , 20 artigos atenderam ao processo de seleção.

Resultados

Neste estudo, a pesquisa foi constituída por 20 artigos que foram caracterizados na figura 1, um fluxograma que descreve as etapas do processo de busca bibliográfica, conforme título, autorias, ano de publicação, local e os periódicos em que foram publicados. Todos os estudos revisados pertenceram à literatura internacional e foram publicados em inglês.

A maioria dos estudos foi publicada nos últimos cinco anos, dentre estes trabalhos seis artigos apresentaram o aprendizado profundo (*deep learning*) e três artigos o aprendizado de máquina (*machine learning*) na autoria principal.

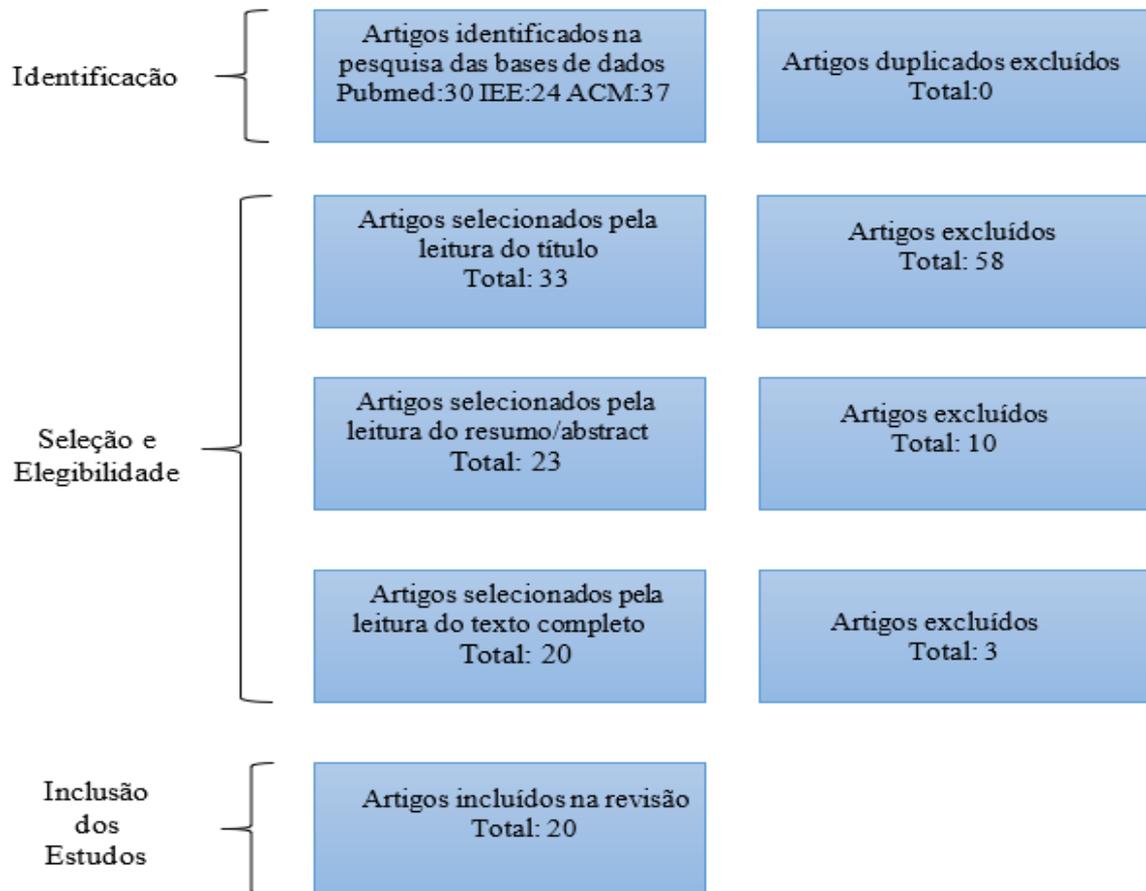


Figura 3. Fluxograma que descreve o número de estudos encontrados por bases de dados, total de artigos, artigos excluídos e selecionados

Foram encontrados uma variedade de publicações da área de diagnóstico por imagem, de inteligência computacional, processamento e análise de dados, bem como de reconhecimento de padrões. Na tabela 1 são apresentados os 20 sistemas de CAD para avaliação da doença de Alzheimer relatados nesses trabalhos incluídos.

TABELA 1 - Principais características dos artigos incluídos na revisão

Artigo e Base de Dados	Anomalias	Interesses	Métricas de Avaliação
Spasov et al, 2019Pubmed⁽¹⁶⁾	Comprometimento cognitivo leve	Desenvolver um sistema de arquitetura de rede neural com convoluções separáveis e agrupadas em 3D	O algoritmo foi capaz de distinguir os pacientes com CCL que desenvolveram DA em 3 anos daqueles pacientes com CCL estável no mesmo período de tempo, com uma área sob a curva (AUC) de 0,925 e uma precisão validada cruzada de 10% de 86%, sensibilidade de 87,5% e especificidade de 85%
Basaia et al,2018Pubmed⁽¹⁷⁾	Comprometimento cognitivo leve	Construir e validar um algoritmo de aprendizado (redes neurais especificamente convolucionais – CNN) que podem prever o diagnóstico individual de DA	Altíssima precisão, sensibilidade e especificidade (acima de 98%) foram obtidas na classificação DA vs. CN
Ju et al,2018Pubmed⁽¹⁸⁾	Comprometimento cognitivo leve	Ajudar a prevenir a DA numa fase inicial e desenvolver sofisticados sistemas de suporte a decisão clínica	Alcança uma melhoria de cerca de 31,21% da precisão da previsão pelo método de aprendizado profundo proposto, e o desvio padrão reduz em 51,23% , o que significa esse modelo de autoencoder é mais estável e confiável em comparação com os métodos tradicionais, possui especificidade de 81% e sensibilidade de 92%
Duraisamy et al,2018Pubmed⁽¹⁹⁾	Atrofia do hipocampo	Minimizar falsos negativos e falsos positivos, respectivamente	Essa estrutura de classificação proposta atinge 98% de precisão, 83% de sensibilidade e 79,5% de especificidade

Nota: CCL = comprometimento cognitivo leve, CN = controles normais, DA= doença de Alzheimer, vs.= versus

TABELA 1 – Continuação...

Artigo e Base de Dados	Anomalias	Interesses	Métricas de Avaliação
Amoroso et al,2018Pubmed⁽²⁰⁾	Atrofia do hipocampo	Apoiar o diagnóstico da DA e se tornar uma ferramenta útil para outras aplicações de neuroimagem	Fornecer volumes do hipocampo com uma precisão de 3%, as medidas de volume revelam efetivamente a DA com uma área sob a curva AUC1= 0,08± 0,02. Os resultados mostraram que os volumes do hipocampo tendem a ser mais específicos (especificidade ~ 0,75 ± 0,04) que recurso sensível (sensibilidade 0,52 ± 0,07)
Khazaei et al,2015Pubmed⁽²¹⁾	Comprometimento cognitivo leve	A combinação das medidas gráficas com a abordagem de aprendizado de máquina, com base na análise de conectividade rs-fMRI pode auxiliar no diagnóstico de DA e MCI	Usando os recursos ideais extraídos das medidas gráficas, conseguiu-se classificar com precisão três grupos (CN, CCL e DA) com precisão de 88,4%. As acurácias de classificação para identificar CN de DA e CCL, DA de CN e CCL e CCL de CN e DA foram 87,3, 97,5 e 72,0%, respectivamente
Ji et al,2019ACM⁽¹⁵⁾	Comprometimento cognitivo leve	Focalizar o diagnóstico precoce de DA em redes neurais convolucionais (ConvNets)	A taxa de precisão das classificações atingiram 97,65% para DA/ comprometimento cognitivo leve 88,37% comprometimento cognitivo leve/ controle normal. DA vs CN especificidade 100%, DA vs. CCL precisão 97,65%, sensibilidade 96%, especificidade 100%, CCL vs. CN precisão 88,37%, sensibilidade 80,56% , especificidade 94%
Korolev et al, 2017IEEE⁽²²⁾	Comprometimento cognitivo leve	Facilitar o uso e não necessitar de nenhuma geração de recursos artesanais	O desempenho de classificação resultante para DA / CN, CCL / CN e CCL / CCL-CN foi de 95%, 85%, 76% precisão e 99%, 88%, 75% COR AUC

Nota: COR = característica de operação do receptor

TABELA 1 – Continuação...

Artigo e Base de Dados	Anomalias	Interesses	Métricas de Avaliação
Lodha et al,2018IEEE ⁽²³⁾	Demência	Fazer uso de algoritmos de aprendizado de máquina para processar esses dados obtidos por tecnologias de neuroimagem para a detecção de Alzheimer	A precisão foi definida como o número de previsões corretas, com base nisso: Máquina de vetor de apoio: 97,56%, Aumento de gradiente: 97,25%, Rede neural: 98,36%, <i>K-Nearest Neighbour</i> 95%, <i>Random Forest</i> : 97,86%
Islam et al,2018IEEE ⁽¹⁴⁾	Desordem neurológica	Demonstrar que esse modelo proposto supera as comparáveis linhas de base da série Open Access of Imaging Studies (OASIS)	Precisão do modelo proposto 99% para o estágio não demente, 75% para o estágio muito leve, 62% estágio leve e 33% para estágio moderado
Gunawardena et al,2016IEEE ⁽²⁴⁾	Comprometimento cognitivo leve	Superar o problema de pré-detectar a doença de Alzheimer	Sensibilidade é de 95,3%, especificidade é de 71,4% e a precisão é de 84,4% com o uso de SVM (<i>Support Vector Machine</i>)
Ahmed et al,2019IEEE ⁽²⁵⁾	Atrofia do hipocampo	Aumentar o nível de precisão comparável aos métodos de ponta, superar a super adaptação do problema, analisar pontos comprovados do cérebro que fornecem características discerníveis para o diagnóstico de DA	Este método alcançou 90,05% de precisão
Sarraf et al,2016IEEE ⁽²⁶⁾	Doença de Alzheimer	Abrir novos caminhos na análise de imagens médicas, permitir que pesquisadores e médicos prevejam potencialmente novos dados. É possível também generalizar esse método para prever diferentes estágios da DA para diferentes faixas etárias. Além disso, esta solução baseada em aprendizado profundo permite que os pesquisadores realizem a seleção e a classificação de recursos com arquitetura única	Usando a rede neural convolucional (CNN) e a arquitetura LeNet-5 com precisão de 96,85%

TABELA 1 - Continuação...

Artigo e Base de Dados	Anomalias	Interesses	Métricas de Avaliação
Khan et al,2019IEEE⁽²⁷⁾	Doença de Alzheimer	Fornecer mapas de ativação de classe (CAM) que demonstra como o modelo proposto se concentra em regiões discriminatórias da imagem que são neuro patologicamente relevantes podem ajudar o profissional de saúde a interpretar o processo de tomada de decisão do modelo	DA vs CN precisão de 99,36%, sensibilidade 98,7%, especificidade 100%. DA vs CCL precisão de 99,2%, sensibilidade de 98,9% e especificidade de 99,5%, CCL vs CN precisão de 99,04%, sensibilidade 99,5% e especificidade de 98,6%
Farooq et al,2017IEEE⁽²⁸⁾	Doença de Alzheimer	Demonstrar o potencial de incorporar modelos profundos diretamente do zero para aprender recursos distintos dos dados de neuroimagem e possuir alto nível de implicações para o processamento médico e de neuroimagem	A técnica proposta resulta em uma precisão de previsão de 98,8%, sensibilidade 97,9% e especificidade de 99,2%
Silva et al,2019IEEE⁽²⁹⁾	Doença de Alzheimer	Propor um modelo para o diagnóstico de DA baseado na extração profunda de características para a classificação por ressonância magnética	Experiências foram realizadas com os algoritmos <i>Random Forest</i> , SVM e K-NN, que obtiveram resultados com precisão de 88%, 95,08% e 85,12%, respectivamente. Para a classificação DA vs CN atingiu precisão de 96,07%, sensibilidade 98,36% e especificidade 95,67%
Raut et al,2017IEEE⁽³⁰⁾	Encolhimento do hipocampo	Esta abordagem está sob implementação e espera-se detectar DA no estágio inicial em comparação com abordagens convencionais	Sensibilidade, especificidade e precisão não descritas

Nota: SVM= *Support Vector Machine* (máquina de suporte vetorial) , K-NN = *K-Nearest Neighbour* (método dos vizinhos próximos)

TABELA 1 - Continuação...

Artigo e Base de Dados	Anomalias	Interesses	Métricas de Avaliação
Senanayake et al, 2018IEE ⁽³¹⁾	Comprometimento cognitivo leve	Este estudo fornece um pipeline de aprendizado profundo que engloba geração, extração fusão e classificação que pode simplificar significativamente o processo de classificação e reduzir a experiência necessária para a interpretação, é o primeiro trabalho que discute a fusão de imagens volumétricas de RM com características baseadas em medidas neuropsicológicas em um aprendizado profundo	Empregou-se uma configuração em que 15% do conjunto de dados é usado como teste, 85% são usados como dados de treinamento. Precisão, sensibilidade e especificidade não descritas
Kazemi et al, 2018IEE ⁽³²⁾	Doença de Alzheimer	Neste estudo o classificador foi capaz de classificar cinco diferentes estágios da doença, (CN) significante preocupação com a memória, (CCL) e DA	A precisão média do modelo foi de 97,63%. Em seguida o modelo foi testado em conjuntos de dados de teste para avaliar a precisão do modelo por classe obtendo uma precisão de 94,97% para DA 95,64% para CCLP 95,89% para CCLT, 98,34% para CN e 94,55% para PSCM
Ambastha et al, 2017IEE ⁽³³⁾	Atrofia do vermis cerebelar correlacionada com a região do hipocampo esquerdo	Caracterização neuroanatômica da DA e prever alterações comportamentais nos pacientes	Modelo auto-associativo que identifica grupos de redes da região cerebral que degeneram junto a DA, possui uma precisão de 81,79% comparado a 74,01% para algoritmos de aprendizado de estrutura baseada em pontuação e 74,42% para algoritmos de aprendizado de estrutura baseados em restrições

Nota: CCLP= comprometimento cognitivo leve precoce, CCLT = comprometimento cognitivo leve tardio, PSM = preocupação significativa com a memória

Como se pode observar nesta revisão, os diferentes estudos realizados apresentam diferentes etapas para a verificação da doença, lembrando que diversas modalidades de imagens médicas são objetos de estudo nos sistemas CAD, mas na presente revisão, nota-se que em todos esses estudos há em comum o uso da ressonância magnética, sendo assim, é fato que a exploração de imagens por esse método são de grande importância.

Discussão

O presente estudo pretendeu obter a melhor evidência quanto ao aprendizado de máquina e seu modo de avaliação em pacientes com Alzheimer. Para tanto, analisou 20 estudos a esse respeito. A busca bibliográfica resultou em 91 artigos, destes 20 foram selecionados com base no título, leitura do resumo e leitura na íntegra.

A maioria dos estudos apresentou uma alta sensibilidade do método ($n=7$), em torno de 87,5% a 97,9%, embora estudos com sensibilidade menores também tenham sido encontrados (52% a 83%). Após a leitura na íntegra, observou-se que poucos estudos apresentaram dados sobre a especificidade ($n=6$) do método de aprendizado de máquina empregado. A maior parte dos artigos apenas apresentavam dados sobre os valores de precisão do método ($n=17$), pois a avaliação das demais métricas de desempenho poderiam ser difíceis de serem mensuradas.

Os artigos foram reunidos por período com a finalidade de propiciar uma análise do volume de artigos que são publicados ao longo dos anos. A partir do ano 2018 constatou-se o maior número de publicações. O maior número de estudos ($n=17$) utilizou bases que contém dados de imagens e de pacientes como a ADNI (*Alzheimer's Disease Neuroimaging Initiative*)⁽³⁴⁾, além de OASIS (*Open Access Series of Imaging Studies*)⁽³⁵⁾ ($n=1$) que disponibiliza gratuitamente conjunto de dados de ressonância magnética do cérebro para a comunidade científica.

Os países que mais publicaram sobre aprendizado de máquina na avaliação da DA, conforme os estudos selecionados para a presente revisão foram: Cingapura ($n=1$), China ($n=1$), Coréia do Sul ($n=1$), Estados Unidos ($n=4$), Índia ($n=3$), Itália ($n=2$). Os demais trabalhos foram publicados em países da Europa.

A pesquisa com o maior valor de precisão observado foi a de Korolev et al⁽²²⁾, ao relacionar duas arquiteturas de convolução de rede 3D para a classificação de Ressonância Magnética cerebral com suas modificações de redes neurais convolucionais simples e residuais com base nos dados decorrentes da ADNI que forneceu um conjunto de dados de exames estruturais de RM, obtendo uma precisão de 99,88% no método de arquitetura de redes neurais

residuais. Dentre os estudos que avaliaram a especificidade do método, os valores variaram entre 52% e 100%. Sendo o método proposto por Ji et al⁽¹⁵⁾ capaz de alcançar 100% de especificidade ao utilizar três Convnets (redes neurais convolucionais) de base que foram projetados, implementados e comparados neste estudo.

Os estudos conduzidos por Silva et al⁽²⁹⁾ e Farooq et al⁽²⁸⁾ apresentaram os maiores valores de sensibilidade do método desenvolvido. Silva et al basearam-se na extração profunda de características para a classificação por RM da DA vs. Controles saudáveis utilizando como banco de dados Ressonância Mínima por Intervalo na Doença de Alzheimer (MIRIAD-*Minimal Interval Resonance Imaging in Alzheimer's Disease*)⁽³⁶⁾, tendo também obtido alta sensibilidade (98,36%) e alta especificidade (95,67%) do método. Em estudo realizado por Farooq et al, utilizando o conjunto de dados ADNI, um resultado semelhante foi encontrado com sensibilidade e especificidade elevadas, 97,9% e 99,2%, respectivamente.

Conclusão

Em suma, esta revisão permitiu uma percepção global sobre inteligência artificial e aprendizado de máquina, por meio da utilização de um método sistemático. A maioria dos estudos analisados mostraram uma perspectiva de aplicação clínica. Os artigos apresentaram diferentes algoritmos de classificação, com o objetivo comum de avaliar a DA nos estágios iniciais e o mais importante, individualmente⁽¹⁷⁾. Observou-se que os algoritmos *Random Forest* (Floresta aleatória), *Support Vector Machine* (Máquina de vetores de suporte) e *K-Nearest Neighbor k-NN* (Método dos vizinhos mais próximos) foram os mais estudados, correspondendo a mais de 30% das pesquisas consideradas no artigo. De fato, a maior parte das pesquisas construíram um modelo que prediz a saída desejada para dados disponíveis através de características estatísticas e preditivas⁽²³⁾.

Por meio da análise dos artigos, foi possível observar que a produção científica mundial sobre inteligência artificial e aprendizado de máquina para o auxílio ao diagnóstico médico da DA tem ganhado cada vez mais relevância com informações importantes para estudos que predizem o diagnóstico individual e comprometimento cognitivo leve com base na ressonância magnética o que auxiliará a prevenção e até tratamento da DA. Dessa forma, selecionar esses estudos, demonstrando suas semelhanças, diferenças e principais achados marcará uma nova era de suporte à decisão clínica.

Referências

1. Albert MS, DeKosky ST, Dickson D, et al. The diagnosis of mild cognitive impairment 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*, 7(3):270–279, 2011.
2. Fôlego GA. ADNET: Computer-Aided diagnosis for Alzheimer's disease using whole-brain 3D convolutional neural network. 14-17, 2018 [disponível na internet].http://repositorio.unicamp.br/bitstream/REPOSIP/333434/1/Folego_Guilherme_Adriano_M.pdf
3. Alzheimer's Association. 2018 Alzheimer's disease facts and figures. *Alzheimer's & Dementia* 14(3):367-429, 2018.
4. Gonçalves EG, Carmo JD. Diagnóstico da doença de Alzheimer na população brasileira: Um levantamento bibliográfico, v. 4, n.2, p 170-176, 2012.
5. Herrera EJ, Caramelli P, Silveira ASB, et al. Epidemiologic survey of dementia in a community-dwelling brazilian population. *Alzheimer Disease & Associated Disorders*, 16(2):103–108, 2002.
6. Plassman BL, Langa KM, Fisher GG, et al. Prevalência de demência nos Estados Unidos: O estudo do envelhecimento, demografia e memória. *Neuroepidemiology*, pp. 125-132, 29 (2007).
7. Panza F, Solfrizzi V, Imbimbo BP, et al. Amyloid-based immunotherapy for Alzheimer's disease in the time of prevention trials: The way forward. pp 405-419,10(2014).

8. Selkoe DJ. Alzheimer's disease: Genes, Proteins, and Therapy. *Physiological Reviews*, 81(2):741-766, 2001. PMID: 11274343
9. Gylys KHD, Fein JA, Yang F, et al. Synaptic changes in Alzheimer's disease: Increased amyloid- β and gliosis in surviving terminals is accompanied by decreased PSD-95 Fluorescence. *The American Journal of Pathology*, 165(5):1809–1817, 2004.
10. Thal LJ, Kantarci K, Reiman EM, et al. The role of biomarkers in clinical trials for Alzheimer disease. *Alzheimer Dis Assoc Disord*, 20(1):6-15, 2006. 16493230[pmid].
11. McKhann GM, Knopman DS, Chertkow H, 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 & association workgroups on diagnostic guidelines for Alzheimer's disease. Alzheimer's & Dementia*, 7(3):263–269, 2011.
12. DeKosky ST, Marek K. Looking backward to move forward: early detection of neurodegenerative disorders. *Science* ; 302(5646): 830–4, 2003.
13. Bron EE, Smits M, Van der Flier WM, et al. Standardized evaluation of algorithms for computer-aided diagnosis of dementia based on structural mri: The CADDementia challenge. *NeuroImage*, 111:562–579, 2015.
14. Islam J, Zhang Y. Early diagnosis of Alzheimer's: A neuroimaging study with deep learning architectures. 2160-7516/18, 2018.
15. Ji H, Liu Z, Yan WQ, et al. Early diagnosis of Alzheimer's disease using deep learning. 978-1-4503-6322-8/19/06, 2019.

16. Spasov S, Passamonti L, Duggento A. Alzheimer's Disease Neuroimaging Initiative, et al. Alzheimer's Disease Neuroimaging Initiative A parameter-efficient deep learning approach to predict conversion from mild cognitive impairment to Alzheimer's disease. *Neuroimage* 2019;189:276–87.
17. Basaia S, Agosta F, Wagner L, et al. Automated classification of Alzheimer 's disease and mild cognitive impairment using a single MRI and deep neural networks, *NeuroImage: Clinica* 1 21 (2018) 101645.
18. Ju R, Hu C, Zhou P, et al. Early diagnosis of Alzheimer's disease based on resting-state brain networks and deep learning, in *IEEE/ACM Transactions on Computational Biology and Bioinformatics*. 2776910, 2018.
19. Duraisamy B, Shanmugam JV, Annamalai J. Alzheimer disease detection from structural MR images using FCM based weighted probabilistic neural network. *Brain Imaging Behav.* 13, 87–110, 2018 <https://doi.org/10.1007/s11682-018-9831-2>
20. Amoroso N, Rocca M, Bellotti R, et al. Alzheimer's disease diagnosis based on the Hippocampal Unified Multi-Atlas Network (HUMAN) algorithm. *Biomedical Engineering Online* 17, 6, 2018.
21. Khazae A, Ebrahimzadeh A, Feremi AB. Application of advanced machine learning methods on resting-state fMRI network for identification of mild cognitive impairment and Alzheimer's disease. *Brain Imaging and Behavior*, 10(3), 799–817, 2015.
22. Korolev S, Safiullin A, Belyaev M, et al. Residual and plain convolutional neural networks for 3d brain mri classification, in *2017 IEEE 14th International Symposium on Biomedical Imaging (ISBI 2017)*, April 2017, pp. 835–838.

23. Lodha P, Talele A, Degaonkar K. Diagnosis of Alzheimer's disease using machine learning, in 2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA), 8697386, 2018.
24. Gunawardena KANNP, Rajapakse RN, Kodikara ND, et al. Moving from detection to pre-detection of Alzheimer's disease from MRI data, in 2016 sixteenth international Conferences (ICTer):324, 2016.
25. Ahmed S, Choi KY, Lee JJ. et al. Ensembles of patch-based classifiers for diagnosis of Alzheimer diseases, *IEEE Access*, vol. 7, pp. 73373–73383, 2019.
26. Sarraf S, Tofighi G. Deep learning-based pipeline to recognize alzheimer's disease using fMRI data,” *bioRxiv*, 2016. [Online]. Available: <http://www.biorxiv.org/content/early/2016/07/31/066910>
27. Khan NM, Abraham N, Hon M. Transfer Learning with Intelligent Training Data Selection for Prediction of Alzheimer's Disease, *IEEE Access*, vol. 7, pp. 72726–72735, 2019.
28. Farooq A, Anwar SM, Awais M, et al. A deep CNN based multi-class classification of Alzheimer's disease using mri. In: *2017 IEEE International Conference on Imaging systems and techniques (IST)*. IEEE, pp. 1–6, 2017.
29. Silva IRR, Silva GSL, Souza RG. et al. Model based on deep feature extraction for diagnosis of Alzheimer's disease. In: 2019 International Joint Conference on Neural Networks (IJCNN). IEE, N-19554, 2019.
30. Raut A, Dalal V, 2017. A machine learning based approach for detection of Alzheimer's disease using analysis of hippocampus region from MRI scan, in: *International Conference*

- on Computing Methodologies and Communication (ICCMC). pp. 236–242. 10.1109/ICCMC.2017.8282683.
31. Senanayake U, Sowmya A, Dawes L. Deep fusion pipeline for mild cognitive impairment diagnosis, in: IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018). pp. 1394–1997. 10.1109/ISBI.2018.8363832.
 32. Kazemi Y, Houghten S. A deep learning pipeline to classify different stages of Alzheimer's disease from fMRI data. In: 2018 IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology (CIBCB) (pp 1–8). IEEE
 33. Ambastha AK, Leong TY. A deep learning approach to neuroanatomical characterisation of Alzheimer's disease. *Stud Health Technol Inform.* 2017;245:1249
 34. Misra C, Fan Y, Davatzikos C. Baseline and longitudinal patterns of brain atrophy in MCI patients, and their use in prediction of short-term conversion to AD: Results from ADNI," *Neuroimage*, vol. 44, no. 4, pp. 1415-1422, 2009.
 35. Marcus DS, Wang TH, Parker J, et al. Open access series of imaging studies (OASIS): cross-sectional MRI data in young, middle aged, nondemented, and demented older adults. *J Cogn Neurosci* 19: 1498 –1507, 2007.
 36. Malone IB, Cash D, Ridgway GR, et al. Miriad - public release of a multiple time point alzheimer's mr imaging dataset, *NeuroImage*, vol. 70, pp. 33–36, 2013.

Conflict of interest: none

Financial source: none

Correspondence

Gabrielly de Lima Baião

Faculdade de Tecnologia de São Paulo

R. Av..Tiradentes 615 - Bom Retiro

01101-010, São Paulo, SP, Brasil.

Phone: (55 11) 91768-0308

devgabriellybaiao@gmail.com
