



PREVISÃO E DIAGNÓSTICO DE ALZHEIMER USANDO TÉCNICAS DE MACHINE LEARNING
PREDICTION AND DIAGNOSIS OF ALZHEIMER'S USING MACHINE LEARNING TECHNIQUES
PREDICCIÓN Y DIAGNÓSTICO DEL ALZHEIMER UTILIZANDO TÉCNICAS DE MACHINE LEARNING

Luiz Fernando da Cunha Silva¹, Letícia Maria Bandeira de Lucena², Samara Martins Nascimento Gonçalves³,
Verônica Maria Lima Silva⁴

e656399

<https://doi.org/10.47820/recima21.v6i5.6399>

PUBLICADO: 5/2025

RESUMO

Este trabalho visa explorar o uso de técnicas de *machine learning* para prever o diagnóstico da doença de Alzheimer, uma condição neurodegenerativa de difícil detecção precoce. O estudo utiliza técnicas como *Support Vector Machine*, *Random Forest* e *K-Nearest Neighbors* aplicados em um conjunto de dados que apresenta informações demográficas, de estilo de vida e histórico médico de pacientes. Os resultados alcançados permitiram avaliar o desempenho dos modelos a partir de métricas, como acurácia, precisão, *recall* e especificidade.

PALAVRAS-CHAVE: Aprendizagem de Máquina. Doença de Alzheimer. Classificação. Aprendizado de Máquina Supervisionado.

ABSTRACT

This study aims to explore the use of machine learning techniques to predict the diagnosis of Alzheimer's disease, a neurodegenerative condition that is challenging to detect early. The study employs techniques such as Support Vector Machine, Random Forest, and K-Nearest Neighbors, applying them to a dataset containing demographic, lifestyle, and medical history information from patients. The results enabled the evaluation of model performance using metrics such as accuracy, precision, recall, and specificity.

KEYWORDS: Machine Learning. Alzheimer Disease. Classification. Supervised Machine Learning.

RESUMEN

Este trabajo tiene como objetivo explorar el uso de técnicas de aprendizaje automático para predecir el diagnóstico de la enfermedad de Alzheimer, una condición neurodegenerativa de difícil detección temprana. El estudio utiliza técnicas como Support Vector Machine, Random Forest y K-Nearest Neighbors, aplicadas a un conjunto de datos que contiene información demográfica, de estilo de vida e historial médico de los pacientes. Los resultados obtenidos permitieron evaluar el rendimiento de los modelos a partir de métricas como exactitud, precisión, recall y especificidad.

PALABRAS CLAVE: Aprendizaje automático. Enfermedad de Alzheimer. Clasificación. Aprendizaje supervisado.

1. INTRODUÇÃO

A Doença de Alzheimer (AD) é neurodegenerativa, sendo a causa mais frequente da demência, comprometendo a memória, o pensamento e o comportamento, com esses sintomas se agravando no decorrer do tempo (Caramelli; Barbosa, 2002). Sua causa é indefinida e há muita dificuldade para se

¹ Graduando em Sistemas de Informação na Universidade Federal Rural do Semi-Árido - UFERSA.

² Graduanda em Sistemas de Informação na Universidade Federal Rural do Semi-Árido - UFERSA.

³ Docente do Departamento de Ciências Exatas e Tecnologia na Universidade Federal Rural do Semi-Árido - UFERSA.

⁴ Docente do Departamento de Sistemas de Computação na Universidade Federal da Paraíba - UFPB.



RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINAR ISSN 2675-6218

PREVISÃO E DIAGNÓSTICO DE ALZHEIMER USANDO TÉCNICAS DE MACHINE LEARNING
Luiz Fernando da Cunha Silva, Letícia Maria Bandeira de Lucena, Samara Martins Nascimento Gonçalves, Verônica Maria Lima Silva

obter diagnósticos na fase inicial da doença (Oliveira; Rabi, 2023). Nesse contexto, o uso de tecnologias revela-se relevante.

O *Machine Learning* (ML) é uma área da Inteligência Artificial (IA) que se dedica ao desenvolvimento de algoritmos e modelos, baseados em matemática e estatística, que permitem o aprendizado do computador a partir de dados (Escovedo; Koshiyama, 2020). Dessa forma, diante da dificuldade de diagnósticos precoces da AD e do potencial das técnicas de ML, esse trabalho foca na seguinte problemática: como técnicas de ML podem ser utilizadas para auxiliar na predição do diagnóstico da AD e qual modelo apresenta melhor desempenho nesse cenário?

Diante do exposto, percebe-se que a aplicação de algoritmos de ML na área da saúde pode representar um avanço significativo na forma como doenças complexas, como o Alzheimer, são detectadas e tratadas. Uma vez que, ao identificar padrões em dados clínicos que podem escapar à observação humana, esses modelos têm o potencial de oferecer diagnósticos mais precisos, especialmente em fases iniciais, contribuindo para estratégias de tratamento mais eficazes e melhor qualidade de vida para os pacientes.

Esse estudo pretende avaliar o desempenho de diferentes algoritmos de ML na predição do diagnóstico da AD, com base em dados clínicos. Para isso, foram definidos os seguintes objetivos específicos: a aplicação de diferentes algoritmos de ML a um conjunto de dados clínicos relacionados à AD; a comparação do desempenho dos algoritmos quanto a métricas como acurácia, precisão, *recall* e *F1-score*; e a análise dos resultados obtidos, além de discutir as potencialidades e limitações dos modelos aplicados.

A organização deste trabalho está estruturada da seguinte forma: na Seção 2 são apresentados os principais conceitos abordados; a Seção 3 discorre sobre os métodos empregados; na Seção 4 os resultados e discussões são descritos; e, por fim, na Seção 5 é apresentada a conclusão, elencando as considerações finais desta pesquisa e os trabalhos futuros.

2. FUNDAMENTAÇÃO TEÓRICA

A seção a seguir apresenta a fundamentação teórica dos principais conceitos abordados nesta pesquisa, incluindo a AD e o ML. Além disso, discutem-se os desafios associados à aplicação ética do ML na área da saúde e são apresentados trabalhos relacionados já publicados na literatura científica.

2.1. Doença de Alzheimer

Machado, Carvalho e Sobrinho (2020) apontam a AD como uma condição neurológica crônica e degenerativa que causa demência progressiva no indivíduo, tendo como característica a destruição dos neurônios colinérgicos, fundamentais para a transmissão dos impulsos nervosos e para a manutenção das atividades cognitivas, como a memória e a aprendizagem. A partir disso, o processo neurodegenerativo da AD, ainda segundo Machado, Carvalho e Sobrinho (2020), compromete de maneira irreversível as habilidades intelectuais e sociais do paciente, resultando em um impacto profundo na sua autonomia e qualidade de vida.



RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINAR ISSN 2675-6218

PREVISÃO E DIAGNÓSTICO DE ALZHEIMER USANDO TÉCNICAS DE MACHINE LEARNING
Luiz Fernando da Cunha Silva, Letícia Maria Bandeira de Lucena, Samara Martins Nascimento Gonçalves, Verônica Maria Lima Silva

Segundo Caramelli e Barbosa (2002), o aumento no quantitativo de casos de doenças crônico-degenerativas tem se elevado como uma consequência do aumento significativo da expectativa de vida da população mundial. Sendo a AD a causa mais frequente de demência a acometer a população idosa. Os autores revelam que os primeiros sintomas da doença são o enfraquecimento da memória e a desorientação espacial, ambos se agravando de forma progressiva, mesmo que possam ocorrer períodos de certa estabilidade clínica para os pacientes.

Oliveira e Rabi (2023) explicam como a detecção precoce da AD é importante para aprimorar o tratamento e diagnóstico da doença, podendo proporcionar mais conforto para o paciente e impedindo o avanço da doença. Os autores também mencionam a dificuldade dos sistemas de saúde em oferecer diagnósticos e cuidados antecipados e precisos em relação à doença.

2.2. Machine Learning

Faceli *et al.*, (2021) apresentam o conceito de ML como uma abordagem da inteligência Artificial que permite que sistemas computacionais sejam capazes de aprimorar seu desempenho com base em dados, utilizando, frequentemente, a indução como mecanismo de generalização de padrões observados em exemplos específicos. Com base nessa percepção, observa-se que algoritmos de ML buscam, a partir da descoberta de padrões em dados, construir modelos que possam realizar previsões, ou classificações, a respeito de um determinado problema complexo sem a necessidade de programação explícita.

Ainda segundo Faceli *et al.*, (2021), o ML pode ser dividido em dois paradigmas: o aprendizado supervisionado e o aprendizado não supervisionado. Com relação ao aprendizado supervisionado, os algoritmos são treinados a partir de conjuntos de dados rotulados, ou seja, os dados apresentam uma descrição explícita do resultado esperado, permitindo que o modelo encontre relações entre as variáveis de entrada e saída. Já no aprendizado não supervisionado, os modelos exploram dados não rotulados, buscando padrões ou agrupamentos.

De acordo com Rashid *et al.*, (2023), técnicas de aprendizado supervisionado são amplamente utilizados na área da saúde, especialmente em: diagnósticos de doenças, previsão de resposta a tratamentos e para medidas de resultados dos pacientes. Desse modo, são aplicadas neste trabalho técnicas de aprendizado de máquina supervisionado para a previsão do diagnóstico da AD, a partir da utilização de diferentes algoritmos de ML, incluindo o *Support Vector Machine (SVM)*, o *Random Forest* e o *K-Nearest Neighbors (KNN)*.

2.3. Desafios da Aplicação de Machine Learning em Diagnósticos Clínicos

Ahuja (2019) explica como o avanço do processamento computacional e o *Big Data* contribuem para a utilização de IA e ML na área da saúde. Segundo o autor, o acúmulo de dados relacionados a saúde, armazenados de forma eletrônica, alinhado aos níveis de precisão que os algoritmos de ML têm alcançado, fazem com que essas ferramentas tenham cada vez mais impacto na área de assistência médica.



RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINAR ISSN 2675-6218

PREVISÃO E DIAGNÓSTICO DE ALZHEIMER USANDO TÉCNICAS DE MACHINE LEARNING
Luiz Fernando da Cunha Silva, Letícia Maria Bandeira de Lucena, Samara Martins Nascimento Gonçalves, Verônica Maria Lima Silva

Farhud e Zokaei (2021) investigaram os problemas éticos sobre o uso de IA na área da saúde e destacaram problemas e dilemas, como: a privacidade e proteção de dados; o consentimento informado e autonomia; as lacunas sociais e justiça; a consulta médica, com empatia e simpatia. Os autores discutiram, também, a necessidade de considerar os princípios da ética médica, antes de incorporar o uso das ferramentas de IA no sistema de saúde.

Com relação à privacidade e proteção de dados, Farhud e Zokaei (2021) indicam que as leis atuais não protegem os dados de saúde dos indivíduos e, sobre a possibilidade de vazamento desses dados, os mesmos podem ser usados para fins maliciosos. Já sobre o consentimento informado e autonomia, os autores destacam que se trata de um processo de comunicação entre paciente e profissional de saúde. Nesse caso, o paciente tem a capacidade de decidir livremente sobre o que fazer com seus dados, permitindo que ele compreenda claramente os procedimentos, riscos e questões relacionadas à privacidade e segurança das suas informações.

Em relação às consultas médicas, Farhud e Zokaei (2021) ressaltam que a integração da inteligência artificial na assistência médica apresenta dificuldades para substituir o relacionamento humano, especialmente devido à importância das emoções e do contato empático na cura e no bem-estar do paciente. Nesse sentido, a ausência desse aspecto humano pode levar à perda de sensibilidade, afeto e comportamento adequado, prejudicando os pacientes.

2.4. Trabalhos Relacionados

Diversos estudos exploram a utilização de técnicas de ML para o diagnóstico precoce da AD, utilizando diferentes tipos de dados, como características clínicas, biomarcadores, sinais de fala e imagens cerebrais. Gómez-Zaragoza *et al.*, (2023) utilizam de transcrições automáticas da fala para o diagnóstico da AD. Os autores utilizaram modelos tradicionais de aprendizado de máquina, como o *Support Vector Machine* (SVM) e o *K-Nearest Neighbors* (KNN), além de Redes Neurais para a classificação da doença. Os resultados foram expressos no estudo pelas métricas: acurácia, precisão, *recall* e *F1-Score*, as quais conseguiram alcançar uma acurácia geral de 85,4%, ao se utilizar as transcrições manuais. Já ao se utilizar as transcrições automáticas da fala, acrescidas de pausas, a acurácia alcançou o valor de 83,3%.

Dara *et al.*, (2023) apresentam um estudo geral a respeito das principais abordagens de ML para a predição da AD. Como resultado, o trabalho apresenta que a combinação de dados clínicos com diferentes modalidades de imagens de ressonância magnética eleva os valores da acurácia dos modelos, que englobam técnicas de Aprendizado Profundo, como Redes Neurais Convolucionais, alcançando, em muitos casos, acurácias superiores aos 90%. O estudo também apresenta as métricas mais utilizadas para a avaliação do modelo, sendo essas: precisão, *recall* e *F1-Score*.

Já Rao *et al.*, (2023) abordam a previsão e classificação da AD através da utilização de imagens tridimensionais de ressonância magnética. O trabalho tem o intuito de apresentar a importância de técnicas automatizadas para a predição da doença, além de realizar o processamento de grandes volumes de dados de imagem para o diagnóstico da AD. Os dados utilizados foram provenientes da *Behavioral Risk Factor Surveillance System* (BRFSS) e apresentam imagens de pacientes com e sem



RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINAR ISSN 2675-6218

PREVISÃO E DIAGNÓSTICO DE ALZHEIMER USANDO TÉCNICAS DE MACHINE LEARNING
Luiz Fernando da Cunha Silva, Letícia Maria Bandeira de Lucena, Samara Martins Nascimento Gonçalves, Verônica Maria Lima Silva

Alzheimer. Com base nos resultados obtidos, observou-se que o modelo proposto, o qual foi desenvolvido a partir da junção do SVM e do *Perceptron Multicamadas* (MLP), conseguiu classificar de maneira eficiente os pacientes, apresentando uma acurácia de 97,47%.

O estudo de Alatrany *et al.*, (2024) visou apresentar um modelo que fosse preciso e explicável, permitindo que especialistas em saúde pudessem compreender quais fatores afetam o progresso da AD. Para isso, utilizaram um conjunto de dados obtidos do *National Alzheimer's Coordinating Center* (NACC), com diversas informações demográficas, históricos de saúde e resultados de testes neuropsicológicos. Como resultado, o modelo SVM alcançou um *F1-score* de 98,9%.

Observando os estudos já realizados, percebe-se que as principais métricas utilizadas para a avaliação dos modelos incluem acurácia, precisão, *recall*, *F1-Score* e especificidade. Seguindo essa observação, essas medidas foram usadas neste trabalho, visando uma análise mais aprofundada e abrangente do desempenho dos modelos treinados, de modo a identificar a detecção ou não da doença.

3. MÉTODOS

Esta seção apresenta os métodos empregados para o desenvolvimento e avaliação dos modelos preditivos para o diagnóstico da AD. Inicialmente, a base de dados utilizada neste estudo é descrita, abordando suas características e categorias de variáveis. Em seguida, detalha-se a implementação dos modelos em Python, a partir dos algoritmos SVM, *Random Forest* e KNN.

3.1. Descrição da Base de Dados

O conjunto de dados *Alzheimer's Disease Dataset* (ADD), desenvolvido por Rabie El Kharoua (2024), foi utilizado nesse estudo, apresentando um total de 2.149 pacientes, com características sintéticas que se relacionam com a presença, ou não, da AD.

A ADD abrange os mais variados aspectos para a compreensão da AD, como: informações relacionadas a questões demográficas, as quais auxiliam na identificação de padrões individuais do paciente, como idade, gênero e etnia; e características relacionadas ao estilo de vida, que conseguem avaliar o impacto de comportamentos cotidianos, tais como exercícios físicos, dieta e consumo de substâncias como álcool e tabaco.

O histórico médico do paciente identifica as condições de saúde preexistentes e o histórico familiar que possam influenciar para o surgimento ou progressão da AD. Além disso, variáveis relacionadas a medições clínicas, avaliações cognitivas, funcionais e sintomáticas, fornecem dados quantitativos sobre aspectos relacionados à saúde física, mental e funcional dos pacientes, permitindo uma compreensão direta da gravidade e impacto da doença.

3.2. Implementação em Python

Para este trabalho, a implementação dos modelos de ML foi realizada utilizando Python, sendo utilizados três algoritmos: SVM, *Random Forest* e KNN, os quais serão apresentados nas seções a



RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINAR ISSN 2675-6218

PREVISÃO E DIAGNÓSTICO DE ALZHEIMER USANDO TÉCNICAS DE MACHINE LEARNING
Luiz Fernando da Cunha Silva, Letícia Maria Bandeira de Lucena, Samara Martins Nascimento Gonçalves, Verônica Maria Lima Silva

seguir¹. A escolha desses se deu pela diversidade nas abordagens que cada um adota para a realização da classificação.

3.2.1 Support Vector Machine (Svm)

O SVM, é um algoritmo supervisionado de ML utilizado tanto para problemas de classificação quanto para regressão (Bansal; Goyal; Choudhary, 2022). Pisner e Schnyer (2020) apresentam que o principal objetivo do SVM, é encontrar um hiperplano que separe as classes de forma que maximize a margem entre os pontos mais próximos de classes diferentes, chamados vetores de suporte. Ou seja, o SVM busca uma função de separação, como ilustrado na Equação 1, na qual w é o vetor de pesos, x é o vetor de características e o b é o termo de viés.

$$f(x) = w \cdot x + b \quad (1)$$

Ao se aplicar esse algoritmo, são obtidos os valores de w e b , os quais maximizam a margem entre as duas classes, ou seja, a distância entre os vetores de suporte e o hiperplano. Assim, a maximização dessa margem reduz a probabilidade de ocorrer *overfitting*, garantindo, então, que o modelo generalize eficientemente os dados desconhecidos.

Quando as classes não são linearmente separáveis, o SVM usa uma função de núcleo, ou *kernel*, para realizar a projeção dos dados em um espaço dimensional mais alto, no qual a separação linear pode ser realizada (Pisner; Schnyer, 2020). O SVM permite diferentes tipos de funções de *kernel*, sendo as mais comuns as funções *Linear*, *Polinomial*, *Radial Basis Function (RBF)* e a *Sigmoid* (Pedregosa *et al.*, 2011).

Para este trabalho, a função *Linear Kernel*, mostrada na Equação 2, foi utilizada, sendo essa correspondente ao produto interno entre dois valores de entrada x_i e x_j , que calcula o quão similar são os vetores, orientando a construção do hiperplano separador. Essa função consegue lidar eficientemente e de forma simplificada com dados que não se encontram linearmente separáveis, sendo, desse modo, adequado para a natureza complexa da classificação da AD.

$$K(x_i, x_j) = x_i \cdot x_j \quad (2)$$

Com base nos conceitos anteriores, o processo de treinamento do modelo SVM foi realizado a partir da função SVC da biblioteca *Scikit-learn*. Inicialmente, o conjunto de dados foi dividido em partes de treino e teste, as quais contaram com 80% dos dados para prática, e 20% para a avaliação do modelo.

Antes da realização do treinamento do modelo, os dados foram normalizados utilizando a técnica *StandardScaler*, a fim de garantir que todas as variáveis estivessem em uma mesma escala.

¹ <https://github.com/luizfernando05/projeto-alzheimer>



RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINAR ISSN 2675-6218

PREVISÃO E DIAGNÓSTICO DE ALZHEIMER USANDO TÉCNICAS DE MACHINE LEARNING
Luiz Fernando da Cunha Silva, Letícia Maria Bandeira de Lucena, Samara Martins Nascimento Gonçalves, Verônica Maria Lima Silva

Esse processo evita que características que apresentam valores mais elevados se sobressaiam daquelas com menores valores, melhorando, então, o desempenho do modelo.

Com os dados preparados, o SVM foi configurado para que o parâmetro *kernel* utilizasse a função linear, e o treinamento foi realizado a partir da função *fit*. Durante a etapa de treino, o algoritmo realizou ajustes nos valores dos pesos w e do viés b , apresentados na Equação 1, visando a maximização das margens entre as classes e encontrar o hiperplano de separação. Por fim, o modelo foi avaliado com base no conjunto de testes, garantindo sua capacidade de generalização.

3.2.2. *Random Forest*

O *Random Forest* é um algoritmo supervisionado de ML baseado no conceito de *ensemble learning*, ou seja, realiza a combinação de múltiplas árvores de decisão para produzir uma predição mais robusta (Breiman, 2001). Cada uma das árvores é construída tendo como base um conjunto aleatório das amostras de treinamento, além de um subconjunto, também aleatório, das características disponíveis. Tal processo, conhecido como *bootstrap aggregation*, ajuda na redução da variância, além de prevenir o *overfitting*, comum em árvores de decisão isoladas.

O processo de funcionamento do *Random Forest* é fundamentado na criação das várias árvores independentes, sendo que cada uma é treinada individualmente para realizar uma classificação baseada em características selecionadas aleatoriamente. Dessa forma, durante a fase de predição, cada árvore gera uma classe como resultado e o modelo faz a decisão pela classe mais votada entre todas as árvores. Este método é particularmente útil ao se considerar conjuntos de dados com variáveis irrelevantes ou ruidosas, já que é capaz de lidar de forma eficiente com essas inconsistências, distribuindo, dessa maneira, a importância entre diversas árvores.

Para este estudo, o treinamento do modelo *Random Forest* foi realizado utilizando a classe *RandomForestClassifier* da biblioteca *Scikit-learn*. Inicialmente, foi realizada a divisão dos dados, onde 80% foram destinados para o treinamento do modelo e os outros 20% para testes. A seguir, as características dos dados foram escaladas, utilizando a função *StandardScaler*, garantindo que todas as variáveis apresentassem o mesmo peso no modelo.

Por fim, o modelo foi treinado utilizando o método *fit*, que ajusta o classificador em relação aos dados de treino. Além disso, o hiperparâmetro $n_estimators$, o qual define a quantidade de árvores, foi selecionado com o valor padrão de 100, e as variáveis preditoras foram, então, ajustadas buscando otimizar o desempenho dos resultados.

3.2.3. *K-Nearest Neighbors (KNN)*

O KNN é um algoritmo supervisionado de ML, usado para problemas de classificação e de regressão, que se baseia na ideia de que objetos que se encontram próximos, em um determinado espaço de características, pertencem a uma mesma classe. Ou seja, os traços de uma determinada classe são agrupados pela similaridade entre estes, fazendo com que o modelo utilize os vizinhos mais próximos para tomar decisões quanto à classe da nova amostra (Bhargava, 2017).



RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINAR ISSN 2675-6218

PREVISÃO E DIAGNÓSTICO DE ALZHEIMER USANDO TÉCNICAS DE MACHINE LEARNING
Luiz Fernando da Cunha Silva, Letícia Maria Bandeira de Lucena, Samara Martins Nascimento Gonçalves, Verônica Maria Lima Silva

A proximidade dos novos dados em relação aos seus vizinhos é medida a partir de diversas métricas, das quais se destacam, segundo Zhang *et al.*, (2023), as distâncias Euclidiana, *Manhattan*, *Chebyshev* e *Mahalanobis*, sendo cada uma adequada para diferentes tipos de dados e aplicações. Neste trabalho, a medida utilizada foi a distância Euclidiana, mostrada na Equação 3, a qual se apresenta como apropriada para dados contínuos e casos em que todas as dimensões têm importâncias semelhantes.

$$d(i \cdot j) = \sqrt{\sum_{n=1}^N (x_i^n - x_j^n)^2} \quad (3)$$

A distância Euclidiana mede a separação direta entre dois pontos x_i e x_j , sendo calculada pela raiz quadrada da soma das diferenças ao quadrado entre suas coordenadas. Considerando o contexto deste trabalho, essa métrica é bastante útil para a identificação de padrões similares, garantindo que cada uma das características possa contribuir igualmente para a classificação.

Uma etapa crucial para o bom desempenho do KNN é a escolha do valor de k , uma vez que este influencia diretamente a precisão e a capacidade do modelo de generalizar para novos dados. Segundo Li *et al.*, (2024), valores muito baixos para o k tendem a gerar modelos que buscam se ajustar de forma excessiva aos dados de treinamento, podendo gerar um *overfitting*. Por outro lado, valores elevados para o k podem tornar o modelo bastante generalizado, resultando em uma acurácia menos precisa para a classificação dos dados.

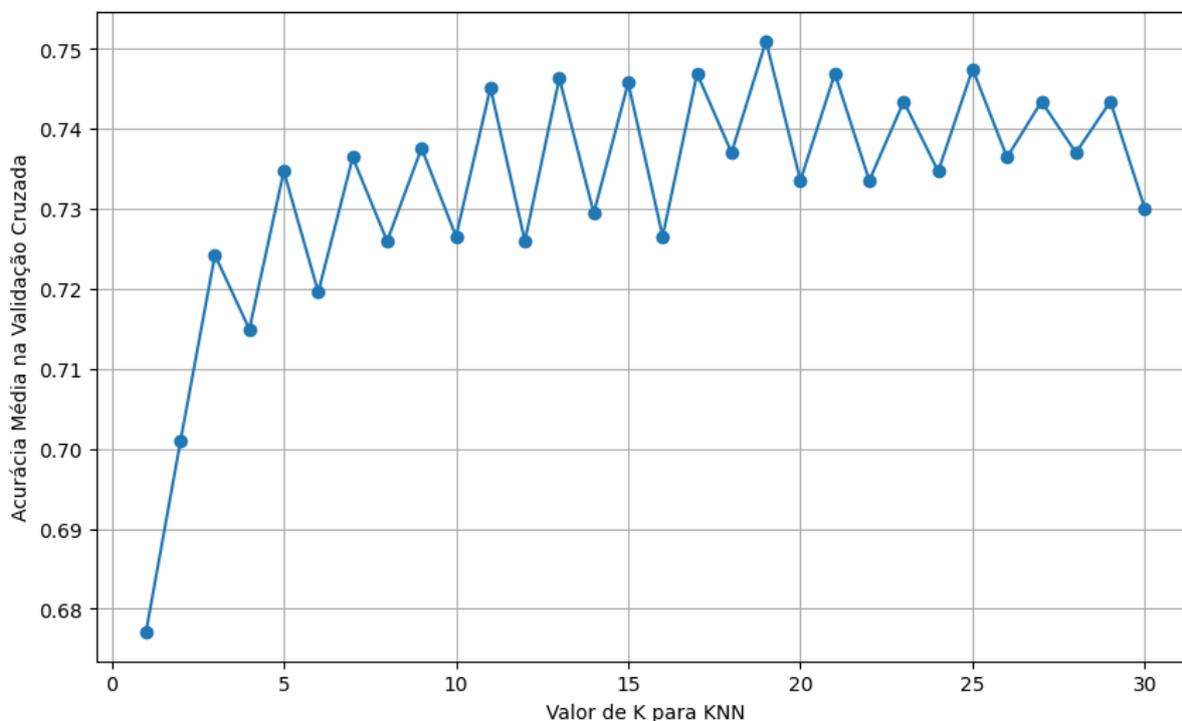
Para este trabalho, a seleção do valor de k foi realizada a partir de uma validação cruzada com valores para o k , variando entre 1 e 30, resultando em um valor de $k = 19$. A Figura 1 ilustra o processo de descoberta desse valor, sugerindo que, para o conjunto de dados utilizado, 19 vizinhos foi o valor que melhor equilibrou a complexidade do modelo e a capacidade de generalização para os novos dados.



RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINAR ISSN 2675-6218

PREVISÃO E DIAGNÓSTICO DE ALZHEIMER USANDO TÉCNICAS DE MACHINE LEARNING
Luiz Fernando da Cunha Silva, Letícia Maria Bandeira de Lucena, Samara Martins Nascimento Gonçalves, Verônica Maria Lima Silva

Figura 1: Relação entre o valor de K e a acurácia para o modelo KNN



Fonte: Autores.

Após a seleção do melhor valor para o k , os dados foram normalizados utilizando a função *StandardScaler* do *Scikit-learn*, buscando a garantia de que todas as características estivessem na mesma escala. Além disso, a divisão dos dados foi realizada, definindo 80% para o treinamento do modelo e 20% para teste. Por fim, o modelo foi treinado utilizando a função *KNeighborsClassifier*, passando o k como parâmetro.

4. RESULTADOS E DISCUSSÃO

Os resultados obtidos a partir da implementação dos modelos de ML são apresentados e discutidos nesta seção. Antes de apresentá-los, foi realizada uma etapa de pré-processamento para a descoberta das melhores características. Essa estratégia é relevante porque um conjunto de dados pode possuir um excesso de atributos, que podem não exercer uma contribuição significativa para o desempenho do modelo. Alguns aspectos podem ser irrelevantes, ou até mesmo redundantes, introduzindo ruído no treinamento e aumentando a complexidade do modelo sem adicionar valor real à previsão. Nesse contexto, a seleção das características mais relevantes torna-se uma tarefa adequada para melhorar a eficiência de modelos de ML, uma vez que esta realiza a identificação das variáveis mais pertinentes para um cenário específico.

Para a seleção das melhores características, foi utilizada a técnica *SelectKBest*, em conjunto do KNN. O *SelectKBest* aplica uma função de pontuação que realiza a avaliação da importância de cada um dos atributos em relação à variável alvo, para então selecionar as k características que apresentaram as melhores pontuações (Pedregosa, 2011). A função de pontuação utilizada foi a



RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINAR ISSN 2675-6218

PREVISÃO E DIAGNÓSTICO DE ALZHEIMER USANDO TÉCNICAS DE MACHINE LEARNING
Luiz Fernando da Cunha Silva, Letícia Maria Bandeira de Lucena, Samara Martins Nascimento Gonçalves, Verônica Maria Lima Silva

$f_classif$, a qual realiza uma série de análises de variância entre cada uma das características e a variável alvo, ajudando, por conseguinte, na identificação dos aspectos que apresentam uma maior relação com a previsão da doença de Alzheimer.

A partir da abordagem descrita, foram avaliados diferentes valores de k para determinar o número ideal de características que resultasse em um melhor desempenho dos modelos. Dessa maneira, o valor ideal para o k foi definido a partir de uma abordagem iterativa utilizando o KNN, o qual foi ajustado com o número adequado de vizinhos, determinado em análise anteriormente descrita neste trabalho. Assim, para cada valor de k , foram selecionadas as melhores características e avaliado o desempenho do modelo por meio da validação cruzada.

A relação entre o número de características selecionadas e o desempenho do modelo KNN apresenta a acurácia média obtida durante o processo de validação cruzada, considerando diferentes valores de k . Observa-se que a inclusão de novas características impacta no desempenho do modelo, sofrendo um considerável aumento, até chegar ao pico, com o valor de $k=5$, e decresce à medida que atributos adicionais, potencialmente tratados como menos relevantes, são inseridos. Com base nessa abordagem, foi determinado que o melhor número de k para o *SelectKBest* é 5, indicando que essa quantidade de características proporcionaria o melhor desempenho para os modelos.

Após a aplicação do *SelectKBest* com o valor de $k = 5$, foi descoberto que os atributos mais relevantes para a previsão da doença de Alzheimer, considerando a base de dados utilizada, foram: *MMSE*, *FunctionalAssessment*, *MemoryComplaints*, *BehavioralProblems* e *ADL*. Tais características mostraram uma relação significativa com a variável alvo *Diagnosis*, que apresenta se o indivíduo foi ou não diagnosticado com a Alzheimer, contribuindo para a melhoria das métricas dos modelos.

O resultado alcançado justifica que a seleção de cinco características é mais relevante, porque não apenas otimiza o desempenho do modelo, mas também resulta em uma redução da complexidade computacional. Da mesma forma que manteve, e até melhorou, sua capacidade de predição. Diante disso, esse processo demonstrou que menos atributos podem levar a um modelo mais eficiente e interpretável, facilitando a análise dos fatores que mais contribuem para a previsão da doença.

4.1. Resultados do SVM

Nesta seção são apresentados os resultados obtidos a partir da aplicação do SVM, utilizando todas as características presentes no conjunto de dados e o subconjunto das melhores características, obtidas a partir da técnica *SelectKBest*.

4.1.1. Resultados do SVM com todas as características

Os resultados relacionados ao treinamento do SVM, com todas as características presentes no conjunto de dados são mostrados na Figura 2. O modelo conseguiu obter uma acurácia geral de 82%, o que demonstra uma boa capacidade de classificação no contexto desse estudo. Entretanto, apesar da demonstração de uma boa acurácia, é de extrema importância a análise de outras métricas, como a precisão, *recall* e matriz de confusão, para que se possa entender de maneira eficiente o comportamento do modelo em relação às classes de interesse.

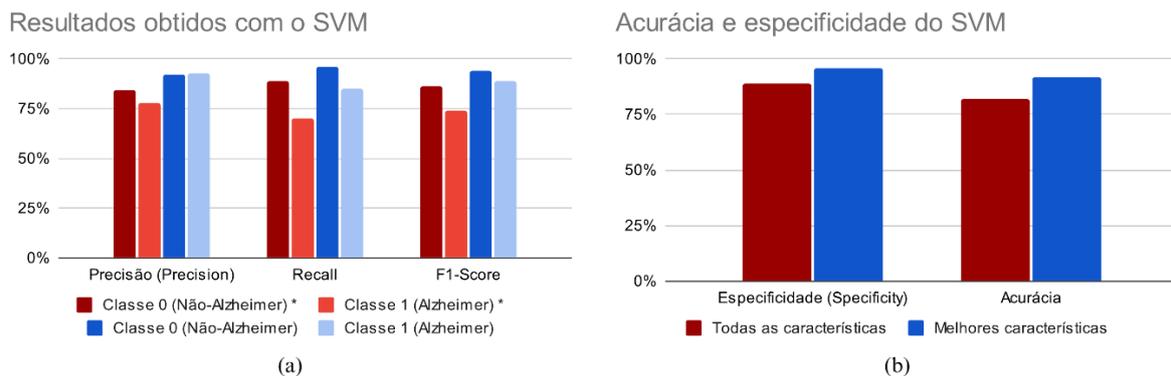


RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINAR ISSN 2675-6218

PREVISÃO E DIAGNÓSTICO DE ALZHEIMER USANDO TÉCNICAS DE MACHINE LEARNING
Luiz Fernando da Cunha Silva, Letícia Maria Bandeira de Lucena, Samara Martins Nascimento Gonçalves, Verônica Maria Lima Silva

Os resultados indicam que o modelo conseguiu atingir uma precisão de 84% para a classe Não-Alzheimer, enquanto, para a classe Alzheimer, se obteve o valor de 78%. Isso demonstra que o SVM teve uma capacidade razoável de identificar corretamente o diagnóstico de Alzheimer, mas ainda apresentou uma dificuldade em reconhecer aqueles que realmente têm a doença. Dessa forma, essa diferença pode indicar que o modelo é mais conservador em suas previsões para a classe Não-Alzheimer.

Figura 2: Resultados de desempenho do SVM



Fonte: Autores.

O *recall* também apresentou uma variação significativa entre as duas classes, sendo 89% para a classe Não-Alzheimer e 70% para a classe Alzheimer. Assim sendo, observa-se que, embora o modelo seja bastante eficiente na identificação da maioria dos casos de Não-Alzheimer, ele deixa de reconhecer cerca de 30% das ocorrências clínicas da doença. Considerando um contexto clínico, essa taxa pode ser preocupante, uma vez que indivíduos podem não ser identificados corretamente, o que poderia dificultar um diagnóstico.

Em relação à matriz de confusão, observa-se que o modelo SVM conseguiu identificar corretamente 246 casos de Não-Alzheimer e 107 casos de Alzheimer. Além disso, foram detectados 31 falsos-negativos, casos de Alzheimer previstos como Não-Alzheimer, e 46 falsos-positivos, casos de Não-Alzheimer previstos como Alzheimer. Tais números mostram que a quantidade de acertos do modelo foi bastante elevada, indicando que o SVM possui uma boa capacidade de generalização, mesmo ao se utilizar todas as características da base de dados.

Por fim, o valor alcançado na especificidade foi de 89% reforçando a ideia de que o modelo apresenta uma alta taxa de identificação para a classe Não-Alzheimer, entretanto, a redução na precisão e o *recall* para a classe Alzheimer evidencia a necessidade de ajustes, ou a consideração de técnicas adicionais para melhorar o desempenho da detecção da doença de Alzheimer.

4.1.2. Resultados do SVM com as *K-BESTS*

Ao aplicar o SVM utilizando apenas as melhores características presentes na base de dados, as quais foram selecionadas pela técnica *SelectKBest*, observou-se uma melhoria significativa no desempenho do modelo treinado, conforme apresentado na Figura 2. A partir da redução dos atributos



RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINAR ISSN 2675-6218

PREVISÃO E DIAGNÓSTICO DE ALZHEIMER USANDO TÉCNICAS DE MACHINE LEARNING
Luiz Fernando da Cunha Silva, Letícia Maria Bandeira de Lucena, Samara Martins Nascimento Gonçalves, Verônica Maria Lima Silva

para somente os cinco mais relevantes, o modelo apresentou uma acurácia geral de 92%, superando, então, o desempenho obtido anteriormente ao se utilizar todas as características.

A partir dos resultados apresentados, percebe-se que a precisão do modelo sofreu um aumento para ambas as classes, atingindo 92% para a Não-Alzheimer e 93% para a Alzheimer. Tais índices demonstram que, ao focar nas características mais relevantes, o modelo não apenas manteve sua capacidade de identificar de forma adequada os casos da doença, mas também conseguiu melhorar, significativamente, sua eficácia em relação à classe Não-Alzheimer.

Outra métrica que demonstrou uma melhoria foi o *recall*, a qual conseguiu alcançar 96% para a classe Não-Alzheimer e 85% para a Alzheimer. Nesse contexto, nota-se que o modelo apresentou a capacidade de identificar quase todos os casos de Não-Alzheimer, além de obter uma margem de erro menor, em comparação ao treinamento com todas as características, na detecção da classe Alzheimer.

A matriz de confusão revelou que o SVM, quando treinado com os melhores atributos, identificou corretamente 267 casos de Não-Alzheimer e 130 casos de Alzheimer. Ademais, somente 10 casos de Alzheimer foram previstos incorretamente como Não-Alzheimer, e 23 casos de Não-Alzheimer foram classificados como Alzheimer. Assim, tais resultados mostram que o modelo apresentou uma melhor eficácia, reduzindo o número de erros de classificação.

Por fim, a especificidade de 96% reforça a eficácia do modelo em distinguir as classes Não-Alzheimer, enquanto a precisão e o *recall* elevadas para a classe Alzheimer, demonstram que o modelo se tornou mais balanceado e confiável em suas previsões.

4.2. Resultados com o *Random Forest*

Nesta subseção, serão apresentados os resultados obtidos a partir da aplicação do *Random Forest* no mesmo conjunto de dados anteriormente usado, com informações sobre Alzheimer.

4.2.1. Resultados do *Random Forest* com todas as características

Ao aplicar o algoritmo *Random Forest* utilizando todos os atributos presentes no conjunto de dados, obtiveram-se os resultados mostrados na Figura 3. Tal modelo apresentou uma acurácia geral de 93%, indicando, assim, um excelente desempenho na tarefa de classificação da doença Alzheimer.

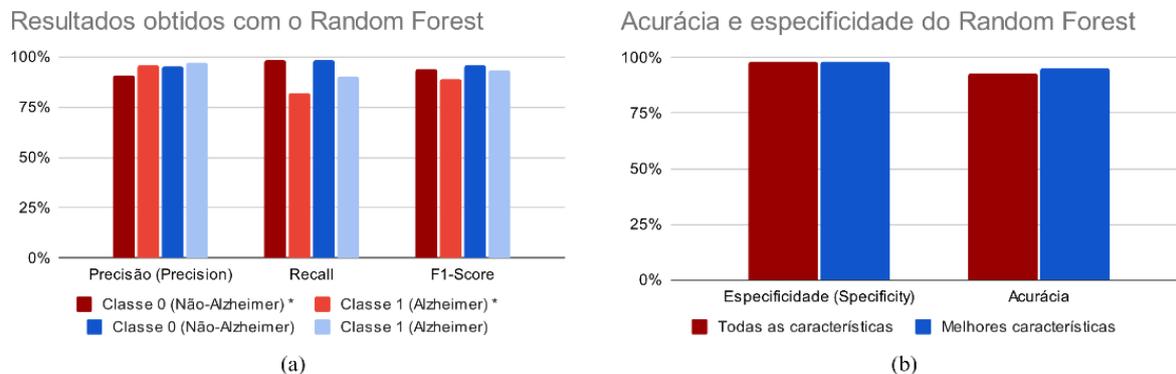
Os resultados alcançados indicam que o *Random Forest* mostrou uma precisão de 91% para a classe Não-Alzheimer, enquanto para a classe Alzheimer, a exatidão foi de 96%. Tais valores demonstram, que o modelo se mostrou eficaz na identificação correta de indivíduos com a doença Alzheimer, superando, inclusive, o desempenho observado para a classe Não-Alzheimer. Isso sugere, então, que esse modelo teve uma menor propensão a classificar falsamente casos de Alzheimer, refletindo em uma alta confiança nas previsões dessa classe.



RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINAR ISSN 2675-6218

PREVISÃO E DIAGNÓSTICO DE ALZHEIMER USANDO TÉCNICAS DE MACHINE LEARNING
Luiz Fernando da Cunha Silva, Letícia Maria Bandeira de Lucena, Samara Martins Nascimento Gonçalves, Verônica Maria Lima Silva

Figura 3: Resultados de desempenho do *Random Forest*



Fonte: Autores.

Ao se observar o *recall*, vê-se uma disparidade bastante significativa entre as classes, uma vez que o modelo alcançou 98% de *recall* para a classe Não-Alzheimer, enquanto para a classe Alzheimer esse valor foi de 82%. Desse modo, tal resultado indica que, embora o *Random Forest* seja excelente na indicação de casos de Não-Alzheimer, ele ainda deixou de detectar 18% dos casos de Alzheimer.

A matriz de confusão traz um complemento para essa análise, mostrando que o modelo conseguiu classificar corretamente 272 casos de Não-Alzheimer e 126 casos de Alzheimer. Contudo, houve 5 falsos negativos, casos de Alzheimer previstos como Não-Alzheimer, e 27 falsos positivos, casos de Não-Alzheimer tidos como Alzheimer. Nesse contexto, percebe-se que a baixa taxa de falsos negativos indica uma alta sensibilidade para a detecção da doença, o que é extremamente desejável em práticas clínicas.

Por fim, a especificidade de 98% para a classe Não-Alzheimer confirma que o modelo *Random Forest* é bastante eficiente em reconhecer de forma correta os indivíduos sem a doença, minimizando, assim, erros de classificação para essa categoria. Apesar disso, o *recall* mais baixa para a classe Alzheimer sugere que ainda há um espaço para melhorias no que diz respeito à identificação de casos da doença.

4.2.2. Resultados do *Random Forest* com as *K-Bests*

Ao aplicar o *Random Forest* utilizando somente as características que se mostraram como as mais relevantes no conjunto de dados, foi possível obter uma acurácia geral de 95%, sendo esse um valor elevado que demonstra um excelente desempenho da classificação (Figura 3). O modelo apresentou uma precisão de 95% para a classe Não-Alzheimer, enquanto para a classe Alzheimer foi obtido o valor de 97%. Tais valores demonstram que o *Random Forest* se mostra, ao utilizar apenas os melhores atributos, ainda mais eficiente em identificar de forma correta os indivíduos com Alzheimer, com uma ligeira melhoria em relação ao uso de todas as características.

Com relação ao *recall* também foi visível uma melhoria considerável, alcançando 98% para a classe Não-Alzheimer e 90% para a Alzheimer. Isso significa que o modelo foi capaz de identificar grande parte dos casos em ambas as classes, com uma pequena fração de 2% das ocorrências de



RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINAR ISSN 2675-6218

PREVISÃO E DIAGNÓSTICO DE ALZHEIMER USANDO TÉCNICAS DE MACHINE LEARNING
Luiz Fernando da Cunha Silva, Letícia Maria Bandeira de Lucena, Samara Martins Nascimento Gonçalves, Verônica Maria Lima Silva

Não-Alzheimer ainda não sendo reconhecidos. Tais resultados sugerem que a seleção dos melhores atributos ajudou no aumento da sensibilidade do modelo, em especial para a classe Alzheimer.

Novamente, a matriz de confusão complementa a análise, mostrando que o modelo conseguiu classificar corretamente 272 casos de Não-Alzheimer e 138 casos de Alzheimer. Entretanto, ainda ocorreram 5 casos de falsos negativos e 15 casos de falsos positivos. A redução do número de falsos positivos, ao se comparar com o modelo que utilizou todas as características da base de dados, demonstra uma melhoria no modelo, reforçando a ideia de que esse apresentou uma melhor eficácia na detecção da doença.

Por fim, têm-se que a especificidade de 98% para a classe Não-Alzheimer traz a confirmação de que o *Random Forest* conseguiu, de forma eficiente, reconhecer corretamente os indivíduos sem a doença. Além disso, a precisão e o *recall* elevadas para ambas as classes sugerem que o modelo, ao utilizar as melhores características, é altamente confiável para a classificação dos dados, minimizando, então, erros de classificação da doença.

4.3. Resultados com *K-Nearest Neighbors* (KNN)

Nesta subseção são expostos os resultados a partir da utilização do algoritmo KNN com todas as características da base de dados e, em seguida, apenas com o subconjunto das melhores características.

4.3.1. Resultados do KNN com todas as características

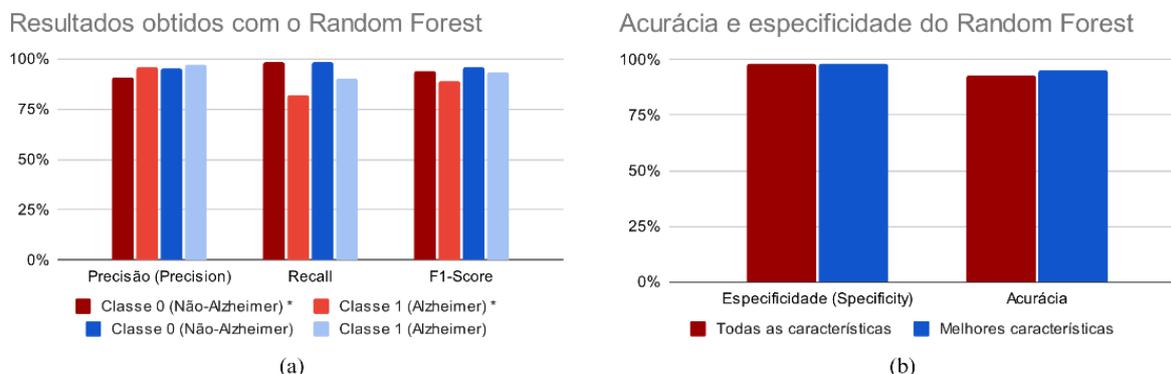
A partir da utilização de todas as características presentes na base de dados com o modelo KNN, foram obtidos os resultados expressos na Figura 4. O modelo apresentou uma acurácia geral de 74%, o que mostra um desempenho razoável na classificação da doença Alzheimer. Além disso, o KNN obteve uma precisão de 73% para a classe Não-Alzheimer, já na classe Alzheimer, este apresentou 79% de precisão. Isso demonstra que o modelo se saiu de forma mais eficaz ao classificar a classe Alzheimer, ou seja, ao identificar os casos positivos. Porém, ao se analisar a métrica de *recall*, nota-se um grande contraste entre a classificação das duas classes: 95% para a classe Não-Alzheimer e 38% para a classe Alzheimer. Isso demonstra que o KNN foi excelente ao lidar com casos de Não-Alzheimer, mas foi insatisfatório ao classificar casos de Alzheimer. Desta forma, pode-se notar que o algoritmo se mostrou ineficaz, visto que ele deixaria de detectar 62% dos casos de Alzheimer e, se tratando de uma doença, isso é severamente crítico.



RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINAR ISSN 2675-6218

PREVISÃO E DIAGNÓSTICO DE ALZHEIMER USANDO TÉCNICAS DE MACHINE LEARNING
Luiz Fernando da Cunha Silva, Letícia Maria Bandeira de Lucena, Samara Martins Nascimento Gonçalves, Verônica Maria Lima Silva

Figura 4: Resultados de desempenho do KNN com todas as características



Fonte: Autores.

A matriz de confusão do modelo mostrou que houve um total de 262 casos de Não-Alzheimer e 58 casos de Alzheimer classificados corretamente. No entanto, o modelo classificou 15 falsos negativos e 95 falsos positivos. Desta forma, nota-se uma taxa elevada de resultados incorretos.

Ao final do experimento, a métrica de especificidade do algoritmo foi de 95% para a classe Não-Alzheimer, o que demonstra que o KNN foi satisfatório ao reconhecer pacientes sem a doença. Contudo, com o *recall* muito aquém do aceitável, torna-se necessário melhorias na aplicação do modelo para que ele não deixe de classificar casos positivos da doença.

4.3.2. Resultados do KNN com as *K-Bests*

Quando utilizado apenas o subconjunto das melhores características do conjunto de dados, foi possível alcançar os resultados indicados na Figura 4. Nesse cenário, foi obtida uma acurácia de 92%, mostrando um excelente desempenho na classificação dos casos. Com essa abordagem, é possível notar que a precisão apresentou um aumento expressivo em ambas as classes, conseguindo alcançar as taxas de 93% para Não-Alzheimer e 90% para Alzheimer. Esse avanço nos resultados demonstra que, ao se utilizar o subconjunto das melhores características, o modelo conseguiu classificar os indivíduos com a doença de maneira ainda mais eficaz.

Em relação ao *recall*, nota-se uma melhoria ainda mais substancial, obtendo os valores de 95% para classe de Não-Alzheimer e 86% para a de Alzheimer. Embora 14% dos casos de Alzheimer ainda não sejam detectados, o modelo demonstrou uma melhora significativa na identificação desses casos, uma vez que o *recall* anterior para Alzheimer era de 62%.

Já a matriz de confusão passou a mostrar que o modelo classificou 262 casos de Não-Alzheimer e 132 casos de Alzheimer corretamente, enquanto houve 15 falsos negativos e 21 falsos positivos. Mesmo que o número de casos de Não-Alzheimer corretos e o número de falsos negativos permaneçam os mesmos, houve uma melhora significativa no aumento de casos de Alzheimer classificados corretamente e na diminuição de falsos positivos apresentados pelo modelo.

Finalmente, a métrica de especificidade de Não-Alzheimer resultou em 95%, mostrando que o KNN efetuou a classificação de pacientes sem a doença de forma correta. Ademais, a significativa



RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINAR ISSN 2675-6218

PREVISÃO E DIAGNÓSTICO DE ALZHEIMER USANDO TÉCNICAS DE MACHINE LEARNING
Luiz Fernando da Cunha Silva, Letícia Maria Bandeira de Lucena, Samara Martins Nascimento Gonçalves, Verônica Maria Lima Silva

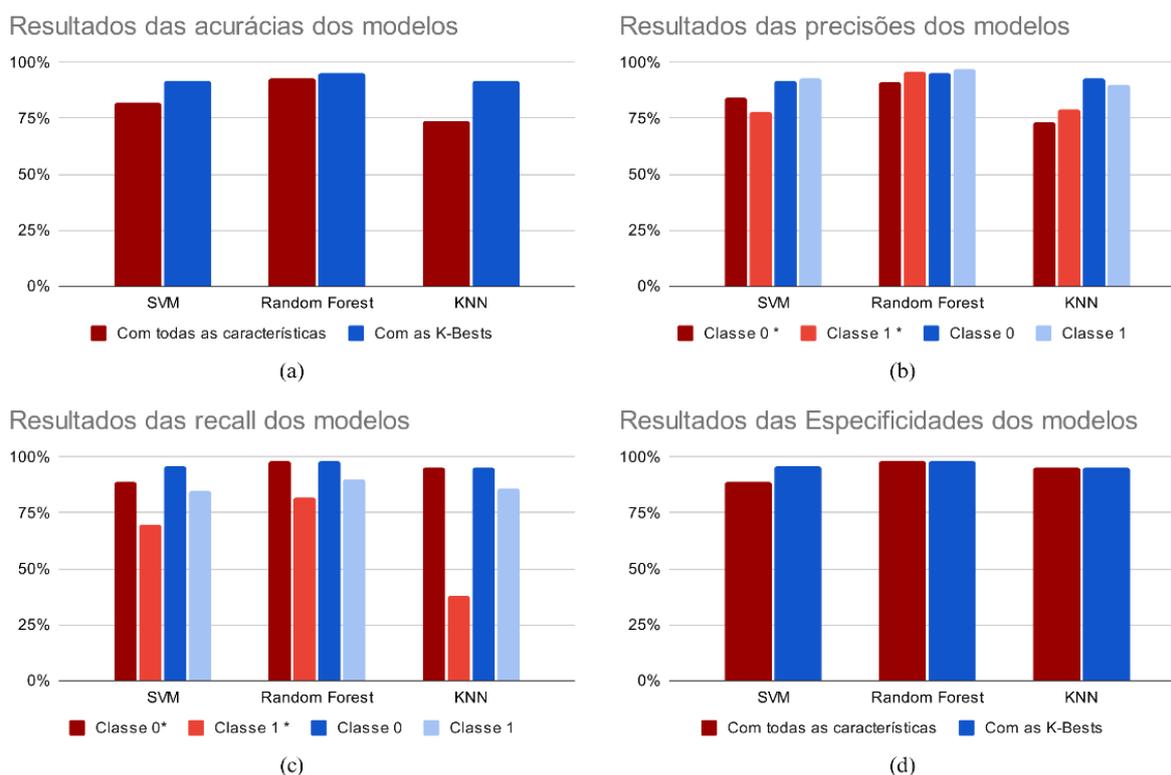
melhoria nas taxas de precisão e *recall* mostraram que a utilização das melhores características teve um alto impacto nos resultados obtidos pelo modelo de classificação.

4.4. Discussão dos Resultados

Nesta seção são comparados os desempenhos dos três modelos para a classificação da doença Alzheimer. São levados em conta seus desempenhos usando todas as características e utilizando apenas as *K-Bests*, comparando as métricas obtidas por cada um dos algoritmos.

Os três modelos apresentaram variação na acurácia quando comparados a utilização de todas as características e a utilização das melhores características, tal variação se mostrou sempre positiva. Porém, como pode ser visto na Figura 5(a), a melhor acurácia obtida nos testes foi a do modelo *Random Forest* ao se utilizar o subconjunto das melhores características; já o modelo que apresentou a maior diferença entre as acurácias, foi o KNN com um aumento de 18 pontos percentuais.

Figura 5: Comparação dos resultados obtidos com os modelos



Fonte: Autores.

Ao se analisar a precisão dos modelos na Figura 5(b), é possível notar que todos eles se beneficiaram do uso das *K-Bests* e conseguiram aumentar suas porcentagens de acerto. Utilizando essa métrica, é possível descobrir qual dos modelos alcançou o melhor resultado ao classificar como positivo os pacientes que realmente possuíam a doença. Então, como mostrado na Figura 5(b), o modelo que melhor atendeu essa tarefa foi o *Random Forest* com 97% de precisão nas classificações da Classe 1 (pacientes com Alzheimer).



RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINAR ISSN 2675-6218

PREVISÃO E DIAGNÓSTICO DE ALZHEIMER USANDO TÉCNICAS DE MACHINE LEARNING
Luiz Fernando da Cunha Silva, Letícia Maria Bandeira de Lucena, Samara Martins Nascimento Gonçalves, Verônica Maria Lima Silva

Outra análise realizada foi a verificação de qual modelo obteve maior *recall*. Na Figura 5(c), é possível notar que o melhor desempenho nessa métrica apresentado pelos modelos foi o resultado do *Random Forest* ao se utilizar as *K-Bests*, seu resultado mostra que o modelo conseguiu classificar 90% dos casos de Alzheimer (Classe 1) corretamente, desta forma, apenas 10% dos casos da doença não foram detectados.

Por fim, foi identificado qual dos modelos obteve o menor número de falsos positivos. Como mostrado na Figura 5(d), o modelo que obteve o melhor desempenho nesse quesito foi o *Random Forest* com 98% de especificidade, independente do conjunto de características usadas.

5. CONSIDERAÇÕES

Neste trabalho, foi explorada a aplicação de algoritmos de ML para previsão do diagnóstico da Doença de Alzheimer. Para isso, foram utilizados três modelos de aprendizado supervisionado: SVM, *Random Forest* e KNN. Os resultados foram obtidos a partir da utilização de dois subconjuntos de dados, o primeiro composto por todos os dados e o segundo composto apenas pelas melhores características, as *k-bests*. Todos os algoritmos se beneficiaram da utilização das *k-bests*, mostrando um desempenho superior ao primeiro teste. Nesse contexto, o KNN a apresentou a maior diferença da acurácia entre os dois testes. Contudo, o *Random Forest* continuou com a melhor acurácia, indo de 93% (todas as características) para 95% (*k-bests*).

Quando analisado qual modelo conseguiu identificar corretamente o maior número de casos da doença, é possível notar que o *Random Forest* também conseguiu o melhor desempenho, independente da classe (Classe 0 ou Classe 1) ou do subconjunto de dados (todas as características ou *k-bests*). O mesmo aconteceu quanto à especificidade, independente do conjunto de características, o modelo em questão também apresentou um desempenho superior aos demais algoritmos. Diante desses resultados e da análise comparativa deles, é possível notar que dentre os algoritmos de ML testados, o *Random Forest* foi o algoritmo com melhor desempenho e consistência na previsão da doença.

Apesar dos resultados alcançados, é relevante discutir as limitações relacionadas a aplicação de técnicas de ML no contexto da AD. No presente estudo, uma limitação importante a ser destacada é a forte dependência do conjunto de dados utilizado, uma vez que, apesar de apresentar uma abundância de características sobre a doença, representa uma amostra sintética de pacientes e condições específicas. Dessa forma, apesar da estrutura do conjunto de dados simular características clínicas da AD, os resultados apresentados podem não garantir desempenho similar em outras populações, que podem apresentar características sociodemográficas ou clínicas distintas. Ademais, por sua natureza tabular, os dados podem limitar a captura de nuances complexas que poderiam ser identificadas em bases de imagens médicas.

Ainda nesse contexto, é importante refletir que apesar dos resultados obtidos, a utilização de algoritmos em saúde enfrenta questões complexas, como a necessidade de interpretabilidade dos modelos, a variabilidade dos dados clínicos entre diferentes populações e instituições de saúde, além do risco de enviesamentos nos dados utilizados para o treinamento. Desse modo, um modelo pode



RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINAR ISSN 2675-6218

PREVISÃO E DIAGNÓSTICO DE ALZHEIMER USANDO TÉCNICAS DE MACHINE LEARNING
Luiz Fernando da Cunha Silva, Letícia Maria Bandeira de Lucena, Samara Martins Nascimento Gonçalves, Verônica Maria Lima Silva

apresentar alta acurácia em um conjunto específico de dados, mas falhar em generalizar seus resultados para outros contextos clínicos, limitando sua aplicabilidade real em ambientes hospitalares diversos.

Como trabalhos futuros, propõe-se a realização de novas pesquisas, utilizando base de dados de imagens cerebrais; a utilização de outros modelos de ML para a previsão da doença; a validação dos modelos criados com dados reais; e a incorporação de aspectos éticos, como a transparência e explicabilidade dos modelos, a fim de garantir que as decisões tomadas pelos algoritmos possam ser compreendidas e validadas por profissionais de saúde.

REFERÊNCIAS

AHUJA, Abhimanyu S. The impact of artificial intelligence in medicine on the future role of the physician. **PeerJ**, v. 7, e7702, 2019. DOI: 10.7717/peerj.7702. Disponível em: <https://peerj.com/articles/7702/>. Acesso em: 27 abr. 2025.

ALATRANY, A. S.; KHAN, W.; HUSSAIN, A. *et al.* An explainable machine learning approach for Alzheimer's disease classification. **Scientific Reports**, v. 14, p. 2637, 2024. Disponível em: <https://doi.org/10.1038/s41598-024-51985-w>. Acesso em: 09 out. 2024.

BANSAL, M.; GOYAL, A.; CHOUDHARY, A. A comparative analysis of K-Nearest Neighbor, Genetic, Support Vector Machine, Decision Tree, and Long Short Term Memory algorithms in machine learning. **Decision Analytics Journal**, [S. l.], v. 3, 2022. Disponível em: <https://doi.org/10.1016/j.dajour.2022.100071>. Acesso em: 14 out. 2024.

BHARGAVA, A. Y. **Entendendo Algoritmos**: um guia ilustrado para programadores e outros curiosos. São Paulo: Novatec Editora, 2017. 264 p. ISBN 978-8575225639.

BREIMAN, L. Random forests. **Machine Learning**, v. 45, p. 5–32, 2001. Disponível em: <https://doi.org/10.1023/A:1010933404324>. Acesso em: 19 out. 2024.

CARAMELLI, Paulo; BARBOSA, Maira Tonidandel. Como diagnosticar as quatro causas mais frequentes de demência?. **Brazilian Journal of Psychiatry**, [S. l.], 2002. DOI <https://doi.org/10.1590/S1516-44462002000500003>. Disponível em: <https://www.scielo.br/j/rbp/a/wK6prKZXgrZwcyTB9TScPpH/>. Acesso em: 25 out. 2024.

DARA, O. A.; LOPEZ-GUEDE, J. M.; RAHEEM, H. I.; RAHEBI, J.; ZULUETA, E.; FERNANDEZ-GAMIZ, U. Alzheimer's Disease diagnosis using machine learning: a survey. **Applied Sciences**, v. 13, 8298, 18 jul. 2023. Disponível em: <https://doi.org/10.3390/app13148298>. Acesso em: 23 set. 2024.

DE OLIVEIRA, Bruna Cristina Bezerra; RABI, Larissa Teodoro. Métodos De Diagnóstico Precoce E Estratégias De Contenção Do Avanço Da Doença De Alzheimer. **Revista Tópicos**, [S. l.], 2023. DOI <https://doi.org/10.5281/zenodo.10350113>. Disponível em: <https://zenodo.org/records/10350113>. Acesso em: 25 out. 2024.

ESCOVEDO, Tatiana; KOSHIYAMA, Adriano. **Introdução a Data Science**: Algoritmos de Machine Learning e métodos de análise. [S. l.: s. n.], 2020.

FACELI, Katti; LORENA, Ana C.; GAMA, João; AL, *et al.* **Inteligência Artificial**: uma abordagem de aprendizado de máquina. 2. ed. Rio de Janeiro: LTC, 2021. *E-book*. p.1. ISBN 9788521637509. Disponível em: <https://app.minhabiblioteca.com.br/reader/books/9788521637509/>. Acesso em: 23 abr. 2025.



RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINAR ISSN 2675-6218

PREVISÃO E DIAGNÓSTICO DE ALZHEIMER USANDO TÉCNICAS DE MACHINE LEARNING
Luiz Fernando da Cunha Silva, Letícia Maria Bandeira de Lucena, Samara Martins Nascimento Gonçalves, Verônica Maria Lima Silva

FARHUD, Dariush D.; ZOKAEI, Shaghayegh. Ethical issues of artificial intelligence in medicine and healthcare. **Iranian Journal of Public Health**, Tehran, v. 50, n. 11, p. i-v, nov. 2021. DOI: 10.18502/ijph.v50i11.7600. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC8826344/>. Acesso em: 27 abr. 2025.

GÓMEZ-ZARAGOZÁ, L.; WILLS, S.; TEJEDOR-GARCIA, C.; MARÍN-MORALES, J.; ALCAÑIZ, M.; STRIK, H. Alzheimer Disease Classification through ASR-based Transcriptions: Exploring the Impact of Punctuation and Pauses. **Interspeech 2023**, Irlanda, p. 2403-2407, 20 ago. 2023. Disponível em: <https://arxiv.org/abs/2306.03443>. Acesso em: 23 set. 2024.

KHAROUA, R. E. **Alzheimer's Disease Dataset**. [S. l.]: Kaggle, 2024. Disponível em: <https://www.kaggle.com/dsv/8668279>. Acesso em: 02 out. 2024.

LI, J.; ZHANG, J.; ZHANG, J.; ZHANG, S. Quantum KNN Classification With K Value Selection and Neighbor Selection. **IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems**, [S. l.], v. 43, n. 5, p. 1332-1345, 2024. DOI 10.1109/TCAD.2023.3345251. Disponível em: <https://ieeexplore.ieee.org/document/10366842>. Acesso em: 20 out. 2024.

MACHADO, A. P. R.; CARVALHO, I. O.; ROCHA SOBRINHO, H. M. da. Neuroinflamação Na Doença De Alzheimer. **Revista Brasileira Militar De Ciências**, [S. l.], v. 6, n. 14, 2020. DOI: 10.36414/rbmc.v6i14.33. Disponível em: <https://rbmc.org.br/rbmc/article/view/33>. Acesso em: 27 abr. 2025.

PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; *et al.* Scikit-learn: Machine learning in Python. **Journal of Machine Learning Research**, v. 12, p. 2825-2830, 2011. Disponível em: <https://scikit-learn.org/stable/>. Acesso em: 18 ago. 2024.

PISNER, D. A.; SCHNYER, D. M. Chapter 6 - Support vector machine. In: MACHINE Learning: Methods and Applications to Brain Disorders. Londres: **Academic Press**, 2020. p. 101-121. ISBN 9780128157398. Disponível em: <https://doi.org/10.1016/B978-0-12-815739-8.00006-7>. Acesso em: 14 out. 2024.

RAO, K. N.; GANDHI, B. R.; RAO, M. V.; JAVVADI, S.; VELLELA, S. S.; KHADER BASHA, S. Prediction and classification of Alzheimer's disease using machine learning techniques in 3D MR images. In: **International Conference On Sustainable Computing And Smart Systems (ICSCSS)**, 2023, Coimbatore, Índia. Anais [...]. Coimbatore: IEEE, 2023. p. 85-90. DOI: 10.1109/ICSCSS57650.2023.10169550.

RASHIDI, Hooman H; ALBAHRA, Samer; ROBERTSON, Scott; TRAN, Nam K; HU, Bo. Common statistical concepts in the supervised Machine Learning arena. **Frontiers in Oncology**, [S. l.], v. 13, 2023. DOI <https://doi.org/10.3389/fonc.2023.1130229>. Disponível em: <https://www.frontiersin.org/journals/oncology/articles/10.3389/fonc.2023.1130229/full>. Acesso em: 24 out. 2024.