

RESEARCH ARTICLE

Inteligência artificial aplicada à saúde: Qualidade na busca de diagnóstico

Artificial intelligence applied to health: Quality in the search for diagnosis

Fabio José Buchedid Vazquez ^{a*} 

^a Pontifícia Universidade Católica de Minas Gerais, 30535-901, Belo Horizonte, Minas Gerais, Brasil.

Resumo

Este estudo investiga a aplicação da Inteligência Artificial (IA) na área da saúde, com foco na melhoria da qualidade dos diagnósticos médicos por meio da análise de imagens. Utilizando a doença de Alzheimer como estudo de caso, a pesquisa explora o funcionamento dos algoritmos de autoaprendizagem e propõe uma solução alternativa para auxiliar o diagnóstico médico. Métodos de data mining e deep learning foram empregados para melhorar a precisão diagnóstica, especialmente em casos simples. Redes neurais convolucionais (CNN) foram utilizadas na análise de imagens médicas, como ressonâncias magnéticas e raios-X, destacando o papel do aprendizado profundo em diagnósticos mais precisos e na previsão da saúde futura dos pacientes. Os resultados indicam que a IA tem um grande potencial para apoiar e, em alguns casos, substituir o diagnóstico médico em situações menos complexas, enquanto, para diagnósticos mais complexos, algoritmos mais robustos são necessários. No entanto, para que essa integração da IA na medicina se torne realidade, é fundamental o investimento em infraestrutura, desenvolvimento de tecnologia e educação. Além disso, a proteção da propriedade intelectual das novas inovações deve ser garantida. Conclui-se que a IA não substituirá os médicos, mas complementarará suas atividades, potencializando o poder de diagnóstico ao combinar a capacidade humana de tomar decisões com a capacidade da IA de analisar grandes quantidades de dados. O equilíbrio entre humanos e máquinas é essencial para um futuro promissor na medicina diagnóstica.

Palavras-chave: Inteligência artificial. Diagnóstico médico. Deep learning. Redes neurais convolucionais. Análise de imagens. Doença de Alzheimer.

Abstract

This study investigates the application of Artificial Intelligence (AI) in healthcare, focusing on improving the quality of medical diagnoses through image analysis. Using Alzheimer's disease as a case study, the research explores the functioning of self-learning algorithms and proposes an alternative solution to assist medical diagnosis. Data mining and deep learning methods were employed to enhance diagnostic accuracy, especially in simple cases. Convolutional Neural Networks (CNNs) were used in the analysis of medical images, such as MRIs and X-rays, highlighting the role of deep learning in more accurate diagnoses and predicting patients' future health. The results indicate that AI has great potential to support and, in some cases, replace medical diagnosis in less complex situations, while more robust algorithms are needed for more complex diagnoses. However, for this integration of AI in medicine to become a reality, investment in infrastructure, technology development, and education is crucial. Additionally, the protection of intellectual property for new innovations must be ensured. It is concluded that AI will not replace doctors but will complement their activities, enhancing diagnostic power by combining human decision-making abilities with AI's capacity to analyze large amounts of data. The balance between humans and machines is essential for a promising future in diagnostic medicine.

Keywords: Artificial intelligence. Medical diagnosis. Deep learning. Convolutional neural networks. Image analysis. Alzheimer's Disease.

Graphical Abstract



*Corresponding author: Fabio J. B. Vazquez. E-mail address: fabio.vazquez@gmail.com
Submitted: 09 September 2024; Accepted: 11 September 2024; Published: 11 September 2024.
© The Author(s) 2024. Open Access (CC BY 4.0).

1. Introdução

A Inteligência Artificial (IA) tem emergido como uma ferramenta transformadora na área da saúde, oferecendo novas possibilidades para melhorar a qualidade dos diagnósticos médicos (Franco, 2014). Este estudo investiga a aplicação da IA na análise de imagens médicas, com um foco específico na doença de Alzheimer, um dos desafios diagnósticos mais complexos da medicina moderna (Dantas, 2023; Smith, 1999). A pesquisa examina como algoritmos de autoaprendizagem, particularmente as redes neurais convolucionais (CNN), podem ser utilizados para aprimorar a precisão dos diagnósticos e oferecer suporte na prática clínica (Wikipedia, 2020).

A análise por imagens médicas, que inclui técnicas como ressonâncias magnéticas e raios-X, é um campo onde a IA pode trazer avanços significativos. O estudo explora o funcionamento desses algoritmos e como eles podem ser integrados na medicina diagnóstica para oferecer soluções alternativas e complementares ao trabalho dos profissionais de saúde. Além disso, aborda a importância do desenvolvimento de tecnologia, investimento em infraestrutura e a necessidade de garantir a proteção da propriedade intelectual das novas inovações.

Este trabalho busca contribuir para a compreensão do potencial da IA na medicina, não como uma substituta dos médicos, mas como uma ferramenta que complementa e potencializa suas habilidades diagnósticas. A integração eficaz da IA na prática médica pode abrir caminho para uma abordagem mais precisa e eficiente na análise de imagens e na previsão da saúde dos pacientes, destacando o papel crucial do equilíbrio entre capacidades humanas e tecnológicas no avanço da medicina diagnóstica.

1.1 Contextualização

As máquinas podem aprender igual a nós, humanos? A resposta é: sim. Essas técnicas são capazes de criar, por si próprias, a partir de experiências passadas, uma hipótese ou função capaz de resolver um problema. Essa hipótese pode ser constituída por um conjunto de regras, que forma um processo de indução por meio de dados passados. Esse processo é denominado de aprendizado máquina (AM) por indução de hipóteses (SAS, 2023a).

Inteligência Artificial (IA) é classificada como uma solução de IA envolve um agrupamento de várias tecnologias, como redes neurais artificiais, algoritmos, sistemas de aprendizado, entre outros que conseguem simular capacidades humanas ligadas à inteligência. Por exemplo, o raciocínio, a percepção de ambiente e a habilidade de análise para a tomada de decisão (UNIVESP, 2018).

Depreende-se que a Inteligência artificial se refere a qualquer técnica que permita que computadores mimetizem a inteligência humana, através de lógica, função se/então (if-then), árvores de decisão e aprendizado de máquina (incluindo aprendizado profundo) entre outras técnicas (Equipe TOTVS, 2024). Essa tecnologia tem avançado em ritmo acelerado demonstrando capacidade das máquinas em lidar com tarefas difíceis através do processamento de grandes conjuntos de dados. Para isso, a pesquisa de IA pode utilizar ferramentas de campos diversos, incluindo ciência da computação, psicologia, probabilidade, neurociência, ciência cognitiva, linguística, pesquisa operacional, economia, teoria de controle, filosofia, otimização e lógica (Schirigatti, 2020a, 2020b).

Podemos dizer que o conceito de IA está relacionado à capacidade de soluções tecnológicas realizarem atividades de um modo considerado inteligente. IAs também podem "aprender

por si mesmas" graças a sistemas de aprendizado que analisam grandes volumes de dados, possibilitando a elas ampliarem seus conhecimentos (Lee, 2019).

A Fig. 1 ilustra a linha do tempo que demonstra a evolução das tecnologias, desde a inteligência artificial até o deep learning.

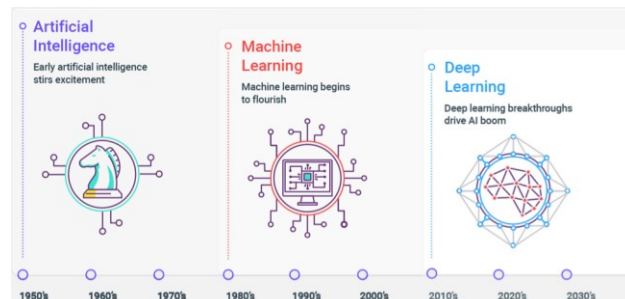


Fig. 1 Linha do tempo demonstrando a evolução das tecnologias desde a inteligência artificial até o deep learning. Fonte: Data-Driven Science (2022).

- ✓ *early artificial intelligence stirs excitement*: a inteligência artificial precoce desperta entusiasmo;
- ✓ *machine learning begins to flourish*: o aprendizado da máquina começa a florescer;
- ✓ *deep learning breakthroughs drive AI boom*: avanços no aprendizado profundo impulsionam o boom da IA

Auto-aprendizagem (machine learning): é um método de análise de dados que automatiza a construção de modelos analíticos. É um ramo da inteligência artificial baseado na ideia de que sistemas podem aprender com dados, identificar padrões e tomar decisões com o mínimo de intervenção humana (SAS, 2023a).

Aprendizagem profunda (deep learning): é um tipo de machine learning que treina computadores para realizar tarefas como seres humanos, o que inclui reconhecimento de fala, identificação de imagem e previsões. Em vez de organizar os dados para serem executados através de equações predefinidas, o deep learning configura parâmetros básicos sobre os dados e treina o computador para aprender sozinho através do reconhecimento de padrões em várias camadas de processamento (SAS, 2023b).

A promessa do deep learning é concretizar sistemas preditivos que se difundem e se adaptam bem, melhoram continuamente à medida que novos dados são adicionados e são mais dinâmicos do que sistemas preditivos baseados em regras de negócios. Você não mais adapta um modelo, você o treina.

1.2. Legislação

O projeto de Lei 21/2020, prevê a criação de regras para o uso de Inteligência Artificial no Brasil, estabelecendo o marco legal do desenvolvimento e uso da IA pelo poder público, por empresas, entidades diversas e pessoas físicas. O texto, em tramitação na Câmara dos Deputados, estabelece princípios, direitos, deveres e instrumentos de governança para a IA. Entre outros pontos, a proposta estabelece que o uso da IA terá como fundamento o respeito aos direitos humanos e aos valores democráticos, a igualdade, a não discriminação, a pluralidade, a livre iniciativa e a privacidade de dados. Além disso, a IA terá como princípio a garantia de transparência sobre o seu uso e funcionamento (Câmara dos Deputados, 2020).

1.3. Registro de Marca e Patente

A proteção às marcas e patentes no Brasil, atualmente, é regulada pela Lei 9.279/96, a chamada Lei de Propriedade Industrial, que legitima o Instituto Nacional de Propriedade Industrial - INPI, como órgão governamental responsável por receber, protocolar, decidir e registrar os pedidos de registro de marcas, patentes, desenhos industriais, softwares, topografias e indicações geográficas. O INPI tem sede na cidade do Rio de Janeiro, e vem informatizando todo seu sistema para que seja possível a realização dos pedidos de registros via internet, sem ser necessário o deslocamento presencial até a sede do Instituto, possibilitando assim o acesso de qualquer lugar do país, a qualquer momento (Weid & Villa Verde, 2020).

Para determinar quais os campos tecnológicos apresentam maior atividade de inovação em IA, em uma classificação mais ampla, a Organização Mundial da Propriedade Intelectual (OMPI) define que as patentes relacionadas à

Inteligência Artificial podem ser agrupadas em três grandes grupos, que refletem as principais dimensões da IA:

(i) Técnicas em IA, também chamadas de tecnologias “core” (ou núcleo, em português) se referem a formas avançadas de modelos estatísticos e matemáticos, permitindo o cálculo de tarefas normalmente executadas por seres humanos;

(ii) Aplicações funcionais, funções como a fala ou visão computacional que podem ser realizadas usando uma ou mais técnicas de IA; e

(iii) Campos de Aplicação, diferentes campos, áreas ou disciplinas onde as técnicas de IA ou suas aplicações funcionais podem ter aplicações, como transporte, agricultura ou ciências médicas e da vida.

Uma amostra do potencial brasileiro, e de onde podemos chegar é verificada pelo gráfico seguinte, acerca do número de pedidos de patentes depositadas no INPI pelos principais depositantes nacionais na área de Inteligência Artificial, conforme demonstra a Fig. 2.




Fig. 2 Número de pedidos de patentes depositadas no INPI pelos principais depositantes nacionais na área de Inteligência Artificial. Fonte: Adaptado de Weid & Villa Verde (2020).

O gráfico evidencia o papel das universidades como centros de pesquisa e inovação. Os números são reveladores: em 2020, elas lideraram o ranking de registros de patentes no INPI na área de Inteligência Artificial. Destacam-se, entre elas, a UNICAMP e a UFMG.

2. Descrição do Problema e da Solução Proposta

Tomar uma decisão constitui um processo pelo qual se escolhe uma ou algumas ações dentre várias possíveis. A escolha é baseada em um conjunto de informações que levam ao intelecto a processar probabilidades de desfecho optando pela mais apazível ou de maior chance de sucesso. A propedêutica médica está reforçada no século XXI pelos instrumentos de apoio às decisões informatizadas que visam reduzir a incerteza diagnóstica e terapêutica. Apesar dos esforços, ainda não foi totalmente decifrado a forma como o médico exerce suas decisões. Nesse cenário, para auxiliar o profissional de saúde, entra o conceito das heurísticas, sistemas epidemiológicos, sistemas informatizados de apoio às decisões. O processo de formulação de hipóteses e diagnósticos diferenciais constitui o El dorado da prática médica. Os dados individuais obtidos pela anamnese e exame físico devem ser agrupados parcimoniosamente em um diagnóstico sindrômico, topográfico ou etiológico que justifique todas as manifestações clínicas. Apesar de todos os recursos disponíveis sempre persistirá a incerteza quanto ao diagnóstico, sendo o foco do clínico a utilização de recursos para redução das dúvidas.

Invariavelmente, o processo de tomada de decisão diagnóstica envolverá fatores dinâmicos, tais como o surgimento de novos sinais e sintomas, informações coletadas de forma

incompleta, de difícil acesso ou pela escassez de recursos tecnológicos que aumentarão a incerteza sobre o caso. O processo seletivo, que visa reduzir a incerteza e simplificar raciocínios complexos sobre os diagnósticos que preenchem elegantemente os requisitos estabelecidos pela história clínica e exame físico, é conhecido como atalhos cognitivos ou heurísticos. Os atalhos cognitivos dependem do conhecimento profundo da epidemiologia, da história natural das doenças e do conceito que os estereótipos em medicina não são absolutos em suas manifestações.

3. Coleta de Dados

A título de estudo prático, podemos exemplificar o diagnóstico da doença de Alzheimer (DA), caracterizada pelo neuropatologista alemão Alois Alzheimer em 1907, é uma afecção neurodegenerativa progressiva e irreversível de aparecimento insidioso, que acarreta perda da memória e diversos distúrbios cognitivos (Smith, 1999). Em geral, a DA de acometimento tardio, de incidência ao redor de 60 anos de idade, ocorre de forma esporádica, enquanto a DA de acometimento precoce, de incidência ao redor de 40 anos, mostra recorrência familiar. A DA de acometimento tardio e a DA de acometimento precoce são uma mesma e indistinguível unidade clínica e nosológica. A escala clínica usada para avaliar o estágio de gravidade da demência em pacientes são: demência muito leve, demência leve, demência moderada, além sem demência, para pacientes onde a doença não foi detectada. Pela divisão em classes temos um problema de classificação, e para classificação podemos usar modelos específicos para o tema um dos muitos disponíveis é o KNN (K-vizinhos mais próximos, ou "K-nearest neighbors") (Dantas, 2023).

O OASIS Brains, também conhecido como Open Access Series of Imaging Studies, é um projeto que visa tornar conjuntos de dados de neuroimagem do cérebro disponíveis gratuitamente para a comunidade científica. Os conjuntos de dados OASIS fornecem à comunidade acesso aberto a um banco de dados significativo de neuroimagem e dados de imagem processados em um amplo espectro demográfico, cognitivo e genético, uma plataforma facilmente acessível para uso em neuroimagem, pesquisa clínica e cognitiva no envelhecimento normal e no declínio cognitivo. Os dados utilizados nesse

documento são os dados da base OASIS-1. Este conjunto consiste em uma coleção transversal de 416 indivíduos com idades entre 18 e 96 anos. Para cada indivíduo, são incluídos 3 ou 4 exames individuais de ressonância magnética ponderada em T1 obtidos em sessões únicas de exame. Os sujeitos são todos destros e incluem homens e mulheres. 100 dos indivíduos incluídos com mais de 60 anos de idade foram diagnosticados clinicamente com doença de Alzheimer (AD) muito leve a moderada (Washington University in St. Louis, s.d.).




Fig. 3 Neuroimaging data sets. Fonte: Washington University in St. Louis (s.d.)

A fase de seleção dos dados é a primeira no processo de descoberta do conhecimento nas atividades de machine learning e ciências dos dados. Nesta fase é escolhido o conjunto de dados contendo todas as possíveis variáveis, também chamadas de características ou atributos, que farão parte da análise. A etapa de seleção possui impacto significativo sobre a qualidade do resultado do processo.

Os dados que iremos utilizar pertencem a uma base de dados sobre diagnóstico de câncer de mama disponível na plataforma Kaggle. A seguir, a célula importa os dados e exibe os cinco primeiros registros disponíveis (Fig. 4). Cada coluna contém informações essenciais sobre os pacientes, incluindo seu ID (identificação), sexo (M/F), mão dominante (Hand), idade (Age), nível de educação (Edu), status socioeconômico (SES), pontuação no Mini-Mental State Examination (MMSE) que avalia a função cognitiva, classificação do Clinical Dementia Rating (CDR) que indica o estágio de gravidade da demência, volume total do cérebro e do crânio (eTIV), Volume Cerebral Total Normalizado (nWBV) que mede o volume cerebral relativo ao tamanho total do cérebro, e o valor único do tamanho relativo do cérebro em relação a um atlas padrão (ASF). Além disso, há o atraso (Delay), medido em meses, entre a aquisição das imagens cerebrais e a avaliação clínica ou cognitiva dos participantes. Esses dados são fundamentais para a análise e estudo da função cerebral e sua relação com fatores demográficos e clínicos (Dantas, 2023).

```
In [1]:
import pandas as pd
dataset = pd.read_csv("/kaggle/input/data-for-classification-of-alzheimers-cases/oasis_cross-sectional.csv")
dataset.head(5)
```

```
Out[1]:
```

	ID	M/F	Hand	Age	Educ	SES	MMSE	CDR	eTIV	nWBV	ASF	Delay
0	OAS1_0001_MR1	F	R	74	2.0	3.0	29.0	0.0	1344	0.743	1.306	NaN
1	OAS1_0002_MR1	F	R	55	4.0	1.0	29.0	0.0	1147	0.810	1.531	NaN
2	OAS1_0003_MR1	F	R	73	4.0	3.0	27.0	0.5	1454	0.708	1.207	NaN
3	OAS1_0004_MR1	M	R	28	NaN	NaN	NaN	NaN	1508	0.803	1.105	NaN
4	OAS1_0005_MR1	M	R	18	NaN	NaN	NaN	NaN	1737	0.848	1.010	NaN

Fig. 4 Tabela de dados obtidas através da plataforma Kaggle, dentro do ambiente Python.

4. Processamento e Tratamento de Dados

O KNN é um modelo de classificação por vizinhança. A letra "K" representa uma variável que indica a quantidade de vizinhos mais próximos usados para classificar problemas. Os modelos KNN são considerados modelos de classificação simples, nos quais a observação dos vizinhos mais próximos leva a deduzir que o objeto observado também pertence à mesma classe que seus vizinhos (Chelliah, 2020; Didática Tech, s.d.; José, 2018).

Após a extração dos dados da plataforma Kaggle foi realizado um pré-processamento para garantir que os dados lidos e interpretados sejam relevantes para o processo de extração de conhecimento. Após isso, foi implementada a transformação dos dados em si, através do algoritmo KNN. Por fim, foram feitas as previsões a partir de novos dados, isto é, após o aprendizado realizado pelo algoritmo KNN sobre a base de dados, novas entradas de dados buscaram classificar se uma nova entrada de fotos de neuroimagem, baseado no aprendizado anterior. Foi traçada uma avaliação para essas previsões, de modo a se obter uma acurácia e concluir se o modelo construído é bom ou ruim nas suas previsões.

A célula ilustrada na Fig. 5 apresenta a contagem de dados faltosos em cada coluna:

```
In [2]: dataset.isna().sum().sort_values()
```

```
Out[2]:
```

ID	0
M/F	0
Hand	0
Age	0
eTIV	0
nWBV	0
ASF	0
Educ	201
MMSE	201
CDR	201
SES	220
Delay	416
dtype:	int64

Fig. 5 Contagem de dados faltosos em cada coluna, dentro do ambiente Python.

As colunas indicadas na **Fig. 6** serão descartadas logo de cara: Delay, devido ao grande volume de dados faltosos, e ID, pois não traz nenhum valor estatístico imediato, embora o código do ID esteja relacionado às visitas no conjunto de dados. Além da coluna Hand, já que foi notado que todos os avaliados são destros.

```
In [3]: print("Mão dominante:", len(dataset['Hand'].unique()))
dataset.drop(['Delay', 'ID', 'Hand'], axis=1, inplace=True)
display(dataset.head(2))
```

Mão dominante: 1

	M/F	Age	Educ	SES	MMSE	CDR	eTIV	nWBV	ASF
0	F	74	2.0	3.0	29.0	0.0	1344	0.743	1.306
1	F	55	4.0	1.0	29.0	0.0	1147	0.810	1.531

Fig. 6 Colunas a serem descartadas, conforme ambiente Python.

Serão também removidas as linhas que apresentem algum dado faltante (**Fig. 7**). Também é observado que para a classe de demência mais avançada 2.0, só temos dois casos, por termos o conjunto completo dos dados e usaremos métodos de separação de treinamento e teste, iremos descartar essa classe, mas não por ser menos importante que as demais, mas por a sua quantidade limitada de dados para a classe.

```
In [4]: print(dataset['CDR'].value_counts())
dataset = dataset.loc[dataset['CDR'] != 2.0]
dataset.dropna(inplace=True)
print('\nQuantidade de dados restantes: ', len(dataset['Age']))
dataset = dataset.reset_index(drop=True)
dataset.head()
```

```
0.0    135
0.5     70
1.0     28
2.0      2
Name: CDR, dtype: int64
```

Out[4]:

	M/F	Age	Educ	SES	MMSE	CDR	eTIV	nWBV	ASF
0	F	74	2.0	3.0	29.0	0.0	1344	0.743	1.306
1	F	55	4.0	1.0	29.0	0.0	1147	0.810	1.531
2	F	73	4.0	3.0	27.0	0.5	1454	0.708	1.207
3	M	74	5.0	2.0	30.0	0.0	1636	0.689	1.073
4	F	52	3.0	2.0	30.0	0.0	1321	0.827	1.329

Fig. 7 Linhas a serem descartadas, e a quantidade de dados restantes (214), conforme ambiente Python.

Será realizado um estudo sobre a correlação entre as variáveis remanescentes e a variável alvo "CDR" (**Fig. 8**). Embora a coluna "M/F" seja qualitativa, será transformada em quantitativa utilizando o método de codificação One Hot-Encoder. A codificação one-hot é um procedimento pelo qual dados categóricos, como dados nominais, são convertidos em recursos numéricos em um conjunto de dados. Geralmente, essa etapa de pré-processamento é necessária, uma vez que os modelos de aprendizado de máquina requerem dados numéricos. Também são definidos rótulos para as classes de CDR onde SD = 0.0, DML = 0.5, DL = 1.0.

Out[5]:

	Age	Educ	SES	MMSE	CDR	eTIV	nWBV	ASF	M/F_F	M/F_M	CDR_
0	74	2.0	3.0	29.0	0.0	1344	0.743	1.306	1.0	0.0	SD
1	55	4.0	1.0	29.0	0.0	1147	0.810	1.531	1.0	0.0	SD
2	73	4.0	3.0	27.0	0.5	1454	0.708	1.207	1.0	0.0	DML
3	74	5.0	2.0	30.0	0.0	1636	0.689	1.073	0.0	1.0	SD
4	52	3.0	2.0	30.0	0.0	1321	0.827	1.329	1.0	0.0	SD

Fig. 8 Correlação de variáveis remanescentes, conforme ambiente Python.

5. Análise e Exploração dos Dados

Com todas as colunas numéricas, é possível analisar a correlação das variáveis (**Fig. 9**). Através da utilização da correlação de Pearson padrão na função corrwith, é observado as variáveis com maior correlação. As variáveis MMSE, nWBV e Age apresentam uma correlação mais forte, sendo somente a idade que influencia positivamente nos casos de Alzheimer. O gráfico de calor exibe a relação entre todas as variáveis.




Fig. 9 Correlograma exibindo as conexões entre as variáveis.

6. Preparação dos Dados para os Modelos de Aprendizado de Máquina

O KNN é um modelo de aprendizado de máquina supervisionado, o que significa que o modelo necessita de dados pré-classificados para o aprendizado do modelo. Essa abordagem pode ser visualizada na **Fig. 10**. A criação de um modelo de classificação facilitaria a emissão de um diagnóstico mais rápido, sem a necessidade do tempo de espera da análise profissional na área, auxiliando e agilizando os processos de tratamento.

A leitura e manipulação dos dados serão feitas majoritariamente com a biblioteca pandas, a qual é utilizada para manipulação de dados.

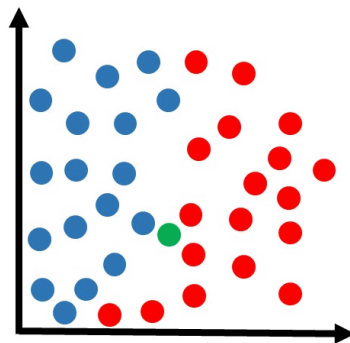


Fig. 10 Classificador KNN. Fonte: Didática Tech. (s.d.). <https://didatica.tech/o-que-e-e-como-funciona-o-algoritmo-knn/>

7. Aplicação de Modelos de Aprendizado de Máquina

A padronização dos dados é uma técnica que ajuda a reduzir a dimensionalidade e, ao mesmo tempo, garante que eles sejam mais úteis, especialmente no cálculo de distâncias por algoritmos. Para realizar essa padronização, podemos utilizar a função StandardScaler do pacote sklearn (Fig. 10). A padronização é um passo importante no pré-processamento de dados antes de aplicarmos algoritmos de aprendizado de máquina, principalmente quando lidamos com variáveis em escalas diferentes. Ao padronizar os dados, os colocamos numa escala com média zero e desvio padrão igual a um, mantendo as relações proporcionais entre eles.

```
In [7]:
from sklearn.preprocessing import StandardScaler
scaler = StandardScaler()
data_temp = pd.DataFrame(scaler.fit_transform(dataset.drop('CDR_', axis=1)), columns=dataset.drop('CDR_', axis=1).columns)
data_temp['CDR_'] = dataset['CDR_']
dataset = data_temp
```

Fig. 10 Pacote sklearn no ambiente Python.

8. Avaliação dos Modelos de Aprendizado de Máquina

Os gráficos da Fig. 11 mostram como os dados de demência estão distribuídos em relação às variáveis mais correlacionadas. É possível observar uma segmentação dos dados ao trabalharmos com três dimensões. Portanto, todas as três variáveis serão incluídas no modelo.

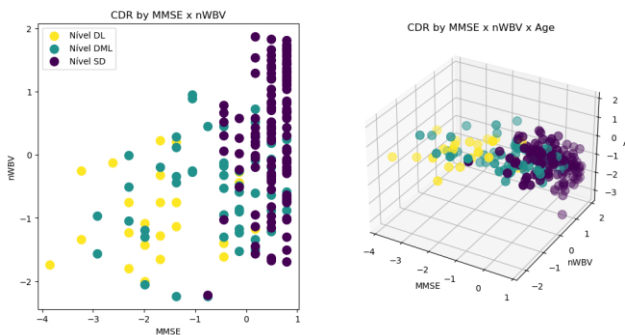


Fig. 11 Distribuição de dados em relação às variáveis.

O KNN utiliza classificação por vizinhança, calculando a distância entre uma variável e as variáveis de seu entorno. Em seguida, classifica a variável com base na classe mais frequente entre os vizinhos mais próximos. As distâncias são calculadas usando principalmente a distância euclidiana ou outra métrica escolhida entre uma variável x e outras do conjunto de treinamento. A fórmula abaixo mostra o cálculo da distância euclidiana:

$$dist(x_i, y_i) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_m - y_m)^2}$$

Após o cálculo das distâncias, é feita uma seleção dos K pontos mais próximos. A classe é geralmente definida pela moda da vizinhança, ou seja, a classe que ocorre com mais frequência entre os K vizinhos mais próximos. Isso torna o KNN um algoritmo de aprendizado de máquina supervisionado, pois requer rótulos

das amostras do conjunto de treinamento para fazer previsões precisas.

O KNN também pode ser adaptado para problemas de regressão, mas a fórmula é modificada para calcular uma média ponderada das saídas dos K vizinhos mais próximos, em vez de fazer uma votação. Não será necessário criar funções para o KNN devido à quantidade de pacotes disponíveis. No Python, o a classe KNeighborsClassifier do pacote scikit-learn já contém toda a implementação necessária. Além disso, para separar os dados em conjuntos de treinamento e validação, é possível utilizar a função train_test_split do mesmo pacote.

A busca por hiperparâmetros pode ser exaustiva, portanto, recorre-se a métodos automatizados de busca de hiperparâmetros, como o GridSearch. A busca em grade procura a melhor combinação de hiperparâmetros com base em uma lista pré-definida de valores a serem testados para cada parâmetro. Isso permite que o modelo seja ajustado de forma mais eficiente em busca dos melhores hiperparâmetros para obter o melhor desempenho possível. O GridSearchCV, da biblioteca scikit-learn, é uma implementação do GridSearch com validação cruzada, que permite avaliar a performance do modelo em diferentes combinações de hiperparâmetros através da divisão dos dados em conjuntos de treinamento e validação. Assim, o GridSearchCV ajuda a selecionar os melhores hiperparâmetros de forma mais confiável, evitando problemas de overfitting e garantindo a generalização do modelo para novos dados.

Embora a abordagem da classificação tenha sido simples, o modelo teve uma precisão considerável em casos de pessoas sem demência, chegando a 93% de precisão, no entanto, houve uma precisão reduzida em casos de demência leve. Os casos de demência moderada ou severa não foram trabalhados devido à falta de dados na base. O potencial da análise não foi explorado em sua totalidade, pois variáveis como ASF e eTIV, assim como nWBV, contêm informações sobre o tamanho do cérebro e do crânio. A junção dessas variáveis em um mesmo componente pode ser vantajosa para o modelo, e isso pode ser explorado em modelos futuros. Apesar disso, o modelo KNN mostrou-se eficaz na classificação do problema abordado, como mostrado nos dados abaixo, apresentando uma acurácia total de 86%.

9. Discussão dos Resultados

Por que usar a IA na assistência médica? As soluções de inteligência artificial (IA) e de machine learning estão transformando a assistência médica. As empresas de saúde acumularam conjuntos de dados enormes com imagens e registros de saúde, dados populacionais, dados de reclamações e dados de ensaios clínicos. As tecnologias de IA são adequadas para analisar esses dados e descobrir padrões e insights que as pessoas não poderiam localizar por conta própria. Com o deep learning da IA, as empresas de assistência médica podem usar algoritmos para tomar melhores decisões clínicas e de negócios e melhorar a qualidade das experiências oferecidas.

Como a IA suporta a imagiologia na assistência médica: ao complementar a trabalhosa varredura de imagens e triagem de casos, as soluções de IA usadas em imagiologia permitem que cardiologistas e radiologistas descubram insights relevantes que os ajudem a identificar os casos críticos primeiro, fazer diagnósticos mais precisos e evitar possíveis erros, aproveitando a amplitude e complexidade dos registros eletrônicos de saúde. Um estudo clínico típico pode produzir conjuntos de dados enormes com milhares de imagens, gerando quantias massivas de dados que precisam de revisão. Com algoritmos de IA, estudos de todo o mercado de assistência médica podem ser

analisados em busca de padrões e relacionamentos ocultos, o que pode ajudar os profissionais de imagiologia a encontrar informações críticas rapidamente.

Como a IA acelera as decisões clínicas na assistência médica: com enormes volumes de dados de saúde e responsabilidades crescentes, os clínicos se esforçam para encontrar tempo de acompanhar as provas médicas mais recentes e ainda fornecer cuidados centrados no paciente. Ao aplicar tecnologias de machine learning nos dados biomédicos e registros eletrônicos de saúde mais recentes, os profissionais da assistência médica podem extrair rapidamente informações precisas, relevantes, baseiam-se em evidências e que foram analisadas por médicos. Algumas ferramentas de suporte à decisão clínica impulsionadas por IA apresentam processamento de linguagem natural e treinamento que se baseia em domínio a fim de permitir que os usuários digitem perguntas como se estivessem falando pessoalmente com um médico e recebam respostas rápidas e confiáveis.

10. Conclusão

Para casos simples de diagnóstico de saúde, teremos a facilidade da heurística, de sistemas de IA, que nos forneçam com exatidão, uma cura, uma paliativo para alívio, ou de um tratamento; obviamente para casos mais complexos, aonde se dependa da variáveis mais subjetivas, é necessário a “algoritmização” heurística, mais robusta na tentativa de descrever como os seres humanos tomam decisões de fato, podem ser associados aos modelos de data mining (mineração de dados) e deep learning (aprendizado profundo), amparadas em fontes absolutamente confiáveis, acrescido da confiança na entrada de dados fidedigna, que ora dependemos do fornecimento de informação pelo paciente, que infelizmente, nem sempre apresenta condições mentais adequadas. O aprendizado profundo está sendo amplamente utilizado em empresas médicas para aplicações que vão desde o diagnóstico à segmentação de imagens. Ele está ajudando os médicos a diagnosticarem pacientes com mais precisão, fazer previsões sobre a saúde futura dos pacientes e recomendar tratamentos melhores. Redes neurais convolucionais (CNN do inglês Convolutional Neural Network ou

ConvNet) em aprendizagem profunda são adequadas para analisar imagens, como resultados de ressonância magnética ou raios-X.

Ficamos a imaginar o potencial de quanto ainda podemos evoluir no futuro, mas para que esse futuro seja auspicioso e venha a ser uma realidade, é necessário tomarmos decisões ainda hoje, tanto de proteção intelectual de patentes das novas invenções, resguardando a propriedade intelectual, quanto em investimento governamental em infraestrutura, para modernização e desenvolvimento sustentável, e priorização da educação de seu povo, para capacitação humana e intelectual.

A IA vem ajudando os seres humanos a fazerem as coisas de maneira mais eficaz. Não se trata de substituir humanos, é sobre complementar a atividade humana. A tecnologia é muito boa em capacidade infinita. É bom ver milhares de terminais diferentes. Os humanos são muito bons em aprender e tomar decisões, mas às vezes não têm a capacidade de aprender tudo. Unir os dois (Homens e Máquinas) pode ser algo muito poderoso: a busca desse equilíbrio harmônico, é a chave para um futuro promissor.

Contribuições dos Autores

F.J.B.V.: Curadoria de Dados, Redação - Preparação do Rascunho Original; Edição, Revisão e Edição. O Autor leu e aprovou o manuscrito final.

Disponibilidade de Dados

Os dados deste artigo estão disponíveis através da seguinte referência: Vazquez, Fabio José Buchedid. Inteligência Artificial aplicada à Saúde: Qualidade na busca de Diagnóstico. 2024. - Inteligência Artificial e Aprendizado de Máquina, Pontifícia Universidade Católica de Minas Gerais (PUC Minas), Belo Horizonte, 2024. <https://doi.org/10.29327/44424611>

Conflitos de Interesses

O autor declara que não tem interesses conflitantes.

Referências

- Câmara dos Deputados. (2020). Projetos de Lei e Outras Proposições. *PL 21/2020*. Autor Eduardo Bismarck. Estabelece princípios, direitos e deveres para o uso de inteligência artificial no Brasil, e dá outras providências. 04 de fevereiro de 2020. Acesso em 19 de junho de 2024. Disponível em: <https://www.camara.leg.br/proposicoesWeb/fichadetramitacao?idProposicao=223634>
- Chelliah, I. (2020). An Introduction to K-Nearest Neighbors Algorithm. What is KNN? *Towards Data Science*. 23 de novembro de 2020. Acesso em 10 de setembro de 2024. Disponível em: <https://towardsdatascience.com/an-introduction-to-k-nearest-neighbours-algorithm-3ddc99883acd>
- Dantas, J. (2023). Alzheimer's classification using KNN. Usando modelo KNN na classificação de casos de Alzheimer. *Kaggle*. 09 de agosto de 2023. Acesso em 10 de setembro de 2024. Disponível em: <https://www.kaggle.com/code/dantits/alzheimer-s-classification-using-knn>
- Data-Driven Science. (2022). 5 ways Deep Learning is changing our day-to-day life. 28 de maio de 2022. Acesso em 22 de setembro de 2022. Disponível em: <https://datadrivenscience.com/5-ways-deep-learning-is-changing-our-day-to-day-life/>
- Datagy.io. (2023). One-Hot Encoding in Scikit-Learn with OneHotEncoder. 23 de fevereiro de 2022. Acesso em 10 de setembro de 2024. Disponível em: <https://datagy.io/sklearn-one-hot-encode/>
- Deep Dive.(s.d.). From narrow AI to broad AI. Acesso em 23 de setembro de 2021. Disponível em: <https://deep-dive.pharmaphorum.com/magazine/digital-health/narrow-ai-broad-ai-ibm-watson-christina-busmalis/>
- Didática Tech. (s.d.). O que é e como funciona o algoritmo KNN? Acesso em 10 de setembro de 2024. Disponível em: <https://didatica.tech/o-que-e-e-como-funciona-o-algoritmo-knn/>
- Equipe TOTVS. (2024). *Inteligência Artificial: o guia completo sobre IA!* Acesso em 10 de setembro de 2024. Disponível em: <https://www.totvs.com/blog/inovacoes/o-que-e-inteligencia-artificial/>
- Estadão. (2019). Inteligência artificial da IBM ajuda a detectar câncer de mama. Summit Saúde e Bem Estar. 14 de novembro de 2019. Acesso em 22 de setembro de 2021. Disponível em: <https://summitsaude.estadao.com.br/tecnologia/inteligencia-artificial-ibm-cancer-mama/>
- Franco, C. R. (2014). *Inteligência artificial*. Londrina. Editora e Distribuidora Educacional S. A. 180 p.
- Freitas, P. H. C. (2021). Linguagens formais e autômatos: expressões e gramáticas regulares. São Paulo. Laureate.
- Freitas, P. H. C. (2021). Linguagens formais e autômatos: linguagens livres do contexto. São Paulo. Laureate.
- Horta, B. C.; Fonseca, H. (2019). A importância dos registros perante o INPI. *Migalhas*. 26 de abril de 2019. Acesso em 19 de junho de 2024. Disponível em: <https://www.migalhas.com.br/depeso/301001/a-importancia-dos-registros-perante-o-inpi>
- IBM. (s.d.). IBM Watson para watsonx. Veja como o IBM Watson avançou na área de IA empresarial. Acesso em 23 de setembro de 2021. Disponível em: <https://www.ibm.com/br-pt/watson>
- José, I. (2018). KNN (K-Nearest Neighbors) #1. How it works. *Towards Data Science*. 08 de novembro de 2018. Acesso em 10 de setembro de 2024. Disponível em: <https://towardsdatascience.com/knn-k-nearest-neighbors-1-a4707b24bd1d>
- Lee, K-F. (2019). *Inteligência Artificial: Como robôs estão mudando o mundo, a forma como amamos, nos relacionamos, trabalhamos e vivemos*. Rio de Janeiro. Globo Livros, 2019. 292 p.
- Pandas. (s.d.). Acesso em 10 de setembro de 2024. Disponível em: <https://pandas.pydata.org/>
- Red Hat. (2022). O que é multicloud? 10 de outubro de 2022. Acesso em 23 de setembro de 2021. Disponível em: <https://www.redhat.com/pt-br/topics/cloud-computing/what-is-multicloud>
- SAS. (2023a). Machine Learning. O que é e qual sua importância? *SAS Insights*. Acesso

- em 22 de setembro de 2021. Disponível em: <https://www.sas.com/pt_br/insights/analytics/machine-learning.html>.
- SAS. (2023b). Deep Learning. What it is and why it matters. *SAS Insights*. Acesso em 22 de setembro de 2021. Disponível em: <https://www.sas.com/pt_br/insights/analytics/deep-learning.html>.
- Schirigatti, J. L. (2020a). Inteligência artificial e aprendizado de máquina: aprendizagem de máquina e redes neurais. São Paulo. Laureate.
- Schirigatti, J. L. (2020b). Inteligência artificial e aprendizado de máquina: introdução e aplicações da inteligência artificial. São Paulo. Laureate.
- Silva, A. M. M. da, Patrocínio, A. C., & Schiabel, H. (2019). Processamento e análise de imagens médicas. *Revista Brasileira de Física Médica*, 13(1), 34-48. <https://doi.org/10.29384/rbfm.2019.v13.n1.p34-48>
- Silva, G. A. R. da. (2013). O processo de tomada de decisão na prática clínica: a medicina como estado da arte. *Revista da Sociedade Brasileira de Clínica Médica*, 11(1), 75-79.
- Smith, M. de A. C. (1999). Doença de Alzheimer. *Revista Brasileira de Psiquiatria*, 21(supl 2), 03-07. <https://doi.org/10.1590/s1516-44461999006000003>
- Super Interessante. (2018). Alan Turing. O pai das ciências da computação e precursor da inteligência artificial. 11 de setembro de 2018. Acesso em 19 de junho de 2024. Disponível em: <<https://super.abril.com.br/historia/alan-turing/#respond>>.
- Teixeira, H. T.; Tavares, M. F.; Pereira, R. V. M. (2017). *Sistemas digitais*. Londrina. Editora e Distribuidora Educacional S.A. 184 p.
- The Python Oracle. (2023). Resolve warning "A NumPy version =1.16.5 and 1.23.0 is required for this version of SciPy"? 13 de dezembro de 2022. Acesso em 10 de setembro de 2024. Disponível em: <<https://www.youtube.com/watch?v=c5z1ataW3Tc>>.
- UNIVESP. (2018). *Inteligência Artificial - Busca Informada – Heurísticas*. Por Renata Wassermann. Univesp - Universidade Virtual do Estado de São Paulo. 26 de nov. de 2018. Acesso em 22 de setembro de 2021. Disponível em: <<https://www.youtube.com/watch?v=Y9Rs90WBZb8&>>.
- Washington University in St. Louis. (s.d.). Open Access Series of Imaging Studies (OASIS). Acesso em 10 de setembro de 2024. Disponível em: <<https://sites.wustl.edu/oasisbrains/>>.
- Weid, I. von der; Villa Verde, F. R. V. (2020). *Inteligência Artificial: análise do mapeamento tecnológico do setor através das patentes depositadas no Brasil*. Rio de Janeiro. Instituto Nacional da Propriedade Industrial (Brasil) – INPI, Diretoria de Patentes, Programas de Computador e Topografia de Circuitos Integrados - DIRPA, Coordenação Geral de Estudos, Projetos e Disseminação da Informação Tecnológica - CEPIT e Divisão de Estudos e Projetos – DIESP. 33 p.
- Wikipedia. (2019). Teoria dos autômatos. 10 de dezembro de 2019. Acesso em 19 de junho de 2024. Disponível em: <https://pt.wikipedia.org/wiki/Teoria_dos_aut%C3%B4matos>.
- Wikipedia. (2020). Linguagem livre de contexto determinística. 8 de novembro de 2020. Acesso em 19 de junho de 2024. Disponível em: <https://pt.wikipedia.org/wiki/Linguagem_livre_de_contexto_determin%C3%ADstica>.
- Wikipedia. (2020). Rede neural convolucional. Acesso em 22 de setembro de 2021. Disponível em: <https://pt.wikipedia.org/wiki/Rede_neural_convolucional>.

DATASET
REPORTS

journals.royaldataset.com/dr