

DEPARTAMENTO DE ENGENHARIA E TECNOLOGIA

LICENCIATURA EM ENGENHARIA INFORMATICA

**DESENVOLVIMENTO DE UMA INTELIGENCIA ARTIFICIAL
PARA O DIAGNOSTICO DE DOENÇAS CEREBRAIS.**

Autor: Adnesio Moises Suami

Orientador: Edvaldo Carvalho, Lic.

Luanda, 2024

DEPARTAMENTO DE ENGENHARIA E TECNOLOGIA

LICENCIATURA EM ENGENHARIA INFORMATICA

**DESENVOLVIMENTO DE UMA INTELIGENCIA ARTIFICIAL
PARA O DIAGNOSTICO DE DOENÇAS CEREBRAIS.**

▪

Trabalho de fim-de-curso apresentado ao
Instituto Superior de Angola como requisitos
para obtenção do grau de Licenciatura em
Gestão de empresas, sob orientação do
Prof. Edvaldo Carvalho, (Lic)

Autor: Adnesio Moises Suami

Orientador: Edvaldo Carvalho, Lic.

Luanda, 2024

DEPARTAMENTO DE ENGENHARIA E TECNOLOGIA
LICENCIATURA EM ENGENHARIA INFORMÁTICA

DESENVOLVIMENTO DE UMA INTELIGENCIA ARTIFICIAL
PARA O DIAGNOSTICO DE DOENÇAS CEREBRAIS.

O JÚRI

Presidente_____

—

1º

Vogal _____

2º

Vogal _____

Secretário _____

—

CLASSIFICAÇÃO:

DATA DA DEFESA _____ / _____ /

DEDICATORIA

Dedico esse trabalho a toda a minha família, meus pais Adão Suami e Madalena Suami, ao meu falecido avô por toda garra e luz Moises, a todas minhas tias Bitá, Fina, Mana Bela, DJ Kebrado.

Dedico também aos meus primos, Zinho, Beto, Dongo por todo apoio e conhecimento que me passaram.

AGRADECIMENTOS

Em primeiro lugar agradeço a suprema divindade por me conceder a sapiência, saúde, força, vontade e resiliência para esse trajeto que difícil e igual pra todos, mas só com a verdadeira união da grandeza conseguimos chegar onde chegamos concluir com uma estrada difícil e muito importante nas nossas vidas.

Agradeço aos meus pais pela vida antes demais nada e estendendo o agradecimento a energia, educação que eles passaram para mim, nunca desistiram deram tudo si para o bem acadêmico, sempre focaram na conclusão do processo não importando como.

A toda a minha família agradeço as minhas tias, aos meus primos que deram aquela coragem diante do processo, as contribuições direta e indireta para o meu sucesso acadêmico.

Agradecendo também ao Instituto Superior de Angola, e aos seus docentes que foram uma força para conclusão na área científica

Sem esquecer os meus amigos também, por toda garra, conselho e advertências sobre a vida por nutrirem uma amizade que serve como bloco para edificar a grande conquista relativo ao sucesso.

Agradecendo também aos meus colegas, aos meus professores que foram como mentores para mim em especial o professor Edvaldo Carvalho.

Aos meus colegas do ISA o Daniel, Lucas Falau, Mauricio e a toda comunidade do condomínio que foram uma força e um lar para mim.

EPIGRAFE

Distante dos nossos olhos, mas se
aproximando uma era pôs digital.

The Ghost (2023)

RESUMO

O Presente trabalho aborda sobre “Desenvolvimento de uma Inteligência Artificial para o Diagnostico de Doenças Cerebrais”. Tem como tipo de Pesquisa a pesquisa Descritiva, quanto ao modelo de abordagem usamos à pesquisa Quali-quantitativa, a pergunta de partida levantada é “Como o desenvolvimento de uma inteligência artificial para o diagnostico de doenças cerebrais baixaria o elevado indice de morte por Avcs, tumores e câncer no cérebro?”, hipoteticamente acreditamos que, A aplicação de inteligência artificial no diagnóstico de doenças cerebrais em Angola pode melhorar a precisão e a eficiência do processo de diagnóstico, resultando em tratamento mais oportuno e melhores resultados de saúde para os pacientes. O nosso objetivo geral é Desenvolver um sistema de IA especializado para o diagnóstico de doenças cerebrais na realidade angolana, utilizando algoritmos de aprendizado de máquina e redes neurais. Os específicos foram, Melhorar a precisão e a eficiência do diagnóstico de doenças cerebrais, visando reduzir atrasos no tratamento e aumentar as chances de

recuperação dos pacientes angolanos. Definiu-se como população de pesquisa de instituições medica com elevado caso de doenças cerebrais. A amostra baseou-se em algumas fotos de pacientes relativo aos seus cérebros feitas por uma ressonância magnética. Concluimos que os resultados obtidos mostram que a IA pode desempenhar um papel crucial na detecção precoce e na tomada de decisões clínicas mais precisas. Sugerimos a utilizar tecnologias de sensoriamento remoto e dispositivo vestíveis para coletar dados biométricos em tempo real, implementando algoritmos de IA para análise e detecção de padrões que possam indicar mudanças na condição cerebral do paciente.

Palavras-chaves: Inteligência artificial, Diagnóstico, Redes Neurais.

ABSTRACT

This work addresses the “Development of Artificial Intelligence for the Diagnosis of Brain Diseases”. The type of research is Descriptive research, regarding the approach model we use for Quali-quantitative research, the starting question raised is “How would the development of artificial intelligence for the diagnosis of brain diseases lower the high rate of death from strokes, brain tumors and cancer?”, we hypothetically believe that, The application of artificial intelligence in the diagnosis of brain diseases in Angola can improve the accuracy and efficiency of the diagnostic process, resulting in more timely treatment and better health outcomes for patients. Our general

objective is to develop a specialized AI system for diagnosing brain diseases in the Angolan reality, using machine learning algorithms and neural networks. The specific ones were, Improving the accuracy and efficiency of diagnosing brain diseases, aiming to reduce delays in treatment and increase the chances of recovery for Angolan patients. It was defined as a research population from medical institutions with a high incidence of brain diseases. The sample was based on some photos of patients of their brains taken by an MRI. We conclude that the results obtained show that AI can play a crucial role in early detection and more accurate clinical decision-making. We suggest using remote sensing technologies and wearable devices to collect biometric data in real time, implementing AI algorithms to analyze and detect patterns that may indicate changes in the patient's brain condition.

Keywords: Artificial intelligence, Diagnosis, Neural networks.

LISTA DE ABREVIATURAS E SIGLAS

FDA - Food and Drug Administration

SVM - Máquinas de Vetor de Suporte

CT - Tomografia Computadorizada

CV - Visão computacional

ANNs - Redes Neurais Artificiais ANNs

IA - Inteligência Artificial

ML - Machine learning

SVM - Máquinas de vetores de suporte

RM - Ressonâncias magnéticas

TC - Tomografias computadorizadas

WoS - Web of Science Core Collection

• INTRODUÇÃO

O diagnóstico preciso e oportunos de doenças cerebrais são fundamentais para a efetividade dos tratamentos e a qualidade de vida dos pacientes. No entanto, o diagnóstico dessas doenças pode ser desafiador devido à complexidade do sistema nervoso e à variedade de condições que afetam o cérebro. Nesse contexto, o desenvolvimento de uma Inteligência

Artificial (IA) voltada para o diagnóstico de doenças cerebrais tem despertado crescente interesse e mostrado promissoras perspectivas.

A IA tem o potencial de auxiliar médicos e especialistas na identificação e interpretação de padrões em imagens cerebrais, exames clínicos e dados relacionados. Utilizando algoritmos de aprendizado de máquina e redes neurais, a IA pode ser treinada para reconhecer características distintivas de diferentes doenças cerebrais, permitindo uma avaliação mais precisa e eficiente. Ao automatizar e aprimorar o processo de diagnóstico, uma IA especializada pode auxiliar na detecção precoce de doenças cerebrais, facilitando intervenções terapêuticas precoces e aumentando as chances de sucesso do tratamento. Além disso, a IA pode ajudar na redução de erros de diagnóstico, que podem ter consequências graves para os pacientes. No entanto, o desenvolvimento de uma IA para o diagnóstico de doenças cerebrais apresenta desafios técnicos e éticos. É necessário acessar e analisar grandes conjuntos de dados, garantindo sua qualidade e confiabilidade. Além disso, questões éticas relacionadas à privacidade dos pacientes e ao uso responsável da tecnologia devem ser cuidadosamente consideradas.

Esta pesquisa propõe explorar o desenvolvimento de uma IA para o diagnóstico de doenças cerebrais, visando contribuir para um diagnóstico mais preciso e eficiente nessa área crucial da medicina. Ao avançar no conhecimento e na aplicação de técnicas de IA, é possível alavancar a tecnologia para melhorar a qualidade do cuidado de saúde, aprimorando os resultados para os pacientes e auxiliando os profissionais médicos em suas decisões clínicas, assim invocando a seguinte pergunta de partida:

Como o desenvolvimento de uma inteligência artificial para o diagnóstico de doenças cerebrais baixaria o elevado índice de morte por Avcs, tumores e cancer no cérebro?

Hipóteses

- **H1:** A aplicação de inteligência artificial no diagnóstico de doenças

cerebrais em Angola pode melhorar a precisão e a eficiência do processo de diagnóstico, resultando em tratamento mais oportuno e melhores resultados de saúde para os pacientes.

- **H2:** A utilização de algoritmos de aprendizado de máquina e redes neurais na análise de exames de imagem cerebral pode auxiliar na detecção precoce de doenças cerebrais, permitindo intervenções médicas mais precoces e aumentando as chances de sucesso no tratamento.
- **H3:** A aplicação de inteligência artificial no diagnóstico de doenças cerebrais pode ajudar a superar a escassez de especialistas em neurologia em Angola, permitindo o acesso a diagnósticos especializados mesmo em áreas remotas e carentes de recursos médicos.

Objetivos de Estudo

Geral

- Desenvolver um sistema de IA especializado para o diagnóstico de doenças cerebrais na realidade angolana, utilizando algoritmos de aprendizado de máquina e redes neurais.

Específicos

- Melhorar a precisão e a eficiência do diagnóstico de doenças cerebrais, visando reduzir atrasos no tratamento e aumentar as chances de recuperação dos pacientes angolanos.
- Facilitar o acesso a diagnósticos especializados de doenças cerebrais, superando as limitações geográficas e a escassez de especialistas em neurologia por meio da possibilidade de diagnóstico remoto.
- Contribuir para a formação e atualização dos profissionais de saúde angolanos, fornecendo uma ferramenta de suporte ao diagnóstico que

possa auxiliar na interpretação de exames e na tomada de decisão clínica.

- Promover a aplicação de tecnologias inovadoras na área da saúde em Angola, impulsionando o desenvolvimento e a adoção de soluções baseadas em IA para melhorar a qualidade e o acesso aos cuidados de saúde.
- Estabelecer parcerias estratégicas com instituições de pesquisa e organizações de saúde para o compartilhamento de conhecimento, recursos e dados, visando aprimorar continuamente o desempenho e a eficácia do sistema.

Delimitação e limitação

- **Delimitação:** A delimitação foi feita focada apenas no contexto territorial Angolano, considerando as particularidades do sistema de saúde, recursos disponíveis e características demográficas do país. Isso permitiu uma análise mais aprofundada das necessidades e desafios específicos enfrentados por Angola em relação ao diagnóstico de doenças cerebrais no ano 2023.
- **Limitação:** Limitamos a nossa pesquisa nas unidades de saúde da província de Luanda, no ano de 2024.

Justificativa

- **Justificativa no âmbito social:**

O desenvolvimento de uma Inteligência Artificial para o diagnóstico de doenças cerebrais em Angola tem uma relevância social significativa. As doenças cerebrais, como acidentes vasculares cerebrais, Alzheimer e Parkinson, têm um impacto devastador na vida dos indivíduos e de suas famílias. Angola enfrenta um aumento na incidência dessas doenças devido ao envelhecimento da população e a outros fatores de risco. A falta de

recursos médicos especializados e a dificuldade de acesso a serviços de saúde de qualidade tornam o diagnóstico precoce e preciso um desafio. O desenvolvimento de uma Inteligência Artificial capaz de auxiliar nesse diagnóstico pode trazer benefícios significativos para a sociedade angolana, permitindo um tratamento mais eficaz, melhor gerenciamento dos casos e maior qualidade de vida para os pacientes.

- **Justificativa no âmbito profissional:**

No contexto profissional, o desenvolvimento de uma Inteligência Artificial para o diagnóstico de doenças cerebrais em Angola oferece oportunidades significativas para os profissionais de saúde. Com ferramentas de IA precisas e confiáveis, os médicos e especialistas em neurologia podem otimizar seus processos de diagnóstico, reduzindo o tempo necessário para obter resultados e aumentando a precisão diagnóstica. Isso pode levar a uma melhoria geral na eficiência dos serviços de saúde, permitindo um atendimento mais ágil e adequado aos pacientes. Além disso, a implementação de tecnologias inovadoras no campo da saúde pode atrair profissionais talentosos e impulsionar o avanço da prática médica em Angola.

- **Justificativa no âmbito acadêmico:**

No âmbito acadêmico, o desenvolvimento de uma Inteligência Artificial para o diagnóstico de doenças cerebrais em Angola representa uma contribuição significativa para o avanço da ciência e da pesquisa.

Estrutura do trabalho

A fim de melhor contextualizar, o presente trabalho começara de uma nota introdutória para esclarecer melhor o problema, os objectivos que se

pretende alcançar na justificativa e a delimitação e apresenta três capítulos. No primeiro capítulo são apresentadas da forma geral as definições de termos e conceitos com base na revisão de texto, obras e artigos relacionados ao tema como descrição das tecnologias e ferramentas usadas para o seu desenvolvimento.

No segundo capítulo aborda sobre metodologia de pesquisa por intermédio do qual apresentado os métodos percorridos, os procedimentos em que estão envolvidas as fases de planejamentos.

No terceiro capítulo apresenta e analisa os resultados alcançados por intermédio de metodologia usada tendo como objetivo analisar e detalhar a solução do sistema de acordo com requisitos levantados.

Finaliza então com a conclusão do trabalho desenvolvido esclarecendo os objetivos alcançados e perspectiva de trabalhos futuros.

CAPITULO I: FUNDAMENTAÇÃO TEORICA

- **Definições dos termos e conceitos**
- **Inteligencia Artificial**

"Inteligência Artificial é o estudo de agentes inteligentes, ou seja, qualquer dispositivo que perceba seu ambiente e tome ações que maximizem suas chances de atingir com êxito seus objetivos, onde os agentes inteligentes podem ser humanos, animais ou máquinas" (RUSSELL & NORVIG, 2016).

"A Inteligencia Artificial é a ciência e engenharia de fazer máquinas inteligentes, especialmente programas de computador inteligentes (NG, 2017)".

"Inteligência Artificial é a disciplina que busca automatizar tarefas que requerem percepção humana, raciocínio, aprendizado e tomada de decisões. Ela visa construir sistemas computacionais capazes de realizar essas tarefas

de forma autônoma, ou seja, sem intervenção humana direta" (DOMINGOS, 2018). É importante observar que as definições de inteligência artificial podem variar entre os autores, refletindo suas perspectivas individuais e o contexto em que trabalham.

- **Redes Neurais**

"Uma rede neural é um modelo computacional composto por um grande número de unidades de processamento simples, chamadas de neurônios artificiais, que têm a capacidade de adquirir conhecimento a partir dos dados por meio de um processo de aprendizado" (HINTON, BENGIO & LE CUN, 2015).

Uma rede neural é um modelo de aprendizado de máquina inspirado no funcionamento do cérebro humano, em que as informações são processadas por meio de camadas de neurônios interconectados, permitindo a extração de características e a tomada de decisões com base nos dados de entrada (GOODFELLOW, BENGIO & COURVILLE, 2016).

Uma rede neural é um modelo computacional composto por várias camadas de unidades interconectadas, chamadas de neurônios, que são capazes de aprender e generalizar padrões complexos a partir dos dados de entrada, sendo amplamente utilizado em tarefas de classificação, regressão e processamento de imagens (Raschka & Mirjalili, 2019).

- **Diagnóstico**

Diagnóstico é o processo de identificar uma doença ou condição de saúde em um paciente, com base na avaliação dos sinais, sintomas, exames laboratoriais e informações clínicas disponíveis, a fim de determinar a causa subjacente e fornecer um plano de tratamento apropriado (SACKETT, 2017).

"Diagnóstico é a interpretação de informações clínicas e resultados de exames para determinar a presença ou ausência de uma condição de saúde específica em um paciente. Envolve a coleta e análise de dados, a aplicação

de habilidades clínicas e a utilização de ferramentas de suporte à decisão para chegar a uma conclusão diagnóstica" (SINGH & SITTIG, 2016).

"Diagnóstico é o processo cognitivo complexo de integrar informações clínicas, conhecimento médico, raciocínio lógico e experiência para identificar uma doença ou condição de saúde em um paciente. Envolve a formulação de hipóteses, a seleção e interpretação de exames, a tomada de decisões e a revisão contínua para melhorar a precisão diagnóstica" (GRABER, 2019).

- **Machine learning**

O aprendizado de máquina, ou *machine learning* (ML), é um ramo da inteligência artificial (IA) que explora o estudo e a construção de algoritmos computacionais a partir do aprendizado por dados. O objetivo principal de um modelo de ML é construir um sistema de computador que aprenda com um banco de dados pré-definido e gere, ao final, um modelo de predição, classificação ou detecção. A aplicação de ML na prática é voltada principalmente para o manuseio de bases de dados consolidadas com informações heterogêneas, para as quais há uma limitação do uso das técnicas de estatística convencionais (BECKER, 2019).

Os algoritmos de ML já estão difundidos em diversas áreas, como sistemas bancários para detecção de fraudes, mecanismos de busca na internet, sistemas de vigilância em vídeo, segurança de dados, logística de empresas, robótica e, na medicina, para diagnóstico e prognóstico. Com a digitalização dos prontuários médicos, exames laboratoriais e de imagem, houve um crescimento dos bancos de dados. Esses são fontes para a aplicação de técnicas de ML, visando a prevenção, diagnóstico precoce e o tratamento das doenças.

O aprendizado de máquina é um subcampo da ciência da computação que busca uma interseção de técnicas matemáticas e estatísticas com algoritmos computacionais. ML utiliza algoritmos com o conceito de IA e é aplicada em determinadas situações em que se busca padrões em um conjunto de variáveis com o intuito de prever um resultado específico.

A maioria das técnicas convencionais usadas em sistemas computacionais aplicados à medicina emprega o conceito de algoritmos baseados em regras, chamados de “sistemas especialistas”. Assim, o desenvolvedor codifica os conhecimentos médicos sobre um determinado assunto para esses sistemas, utilizando regras já conhecidas. Já as técnicas de ML manuseiam um grande número de variáveis, buscando uma variedade de novas combinações que possam prever um resultado.

Becker (2019, p.44) definiu um modelo de “3 Vs” para conceituar o termo *big data*: grande volume, alta velocidade e alta variedade de informações exigem novas técnicas de processamento de forma a permitir descobertas e otimizar processos. O termo *big data* pode ser tanto um conjunto de dados de tamanho enorme, que nenhuma das ferramentas tradicionais de gerenciamento de dados é capaz de armazená-los ou processá-los com eficiência, como também pode se referir a um tipo de tecnologia (como instalações de armazenamento, ferramentas e processos).

O processo de desenvolvimento de um algoritmo de ML é dividido em três fases: pré-processamento, treinamento e avaliação do modelo. A primeira fase consiste em organizar o banco de dados, definir a pergunta de pesquisa e dividir os dados em treinamento e teste. No treinamento, o aprendizado pode ocorrer de forma supervisionada ou não supervisionada. O aprendizado supervisionado é baseado no treinamento de uma amostra de dados com a classificação correta já atribuída, enquanto o não supervisionado se refere à capacidade de aprender e organizar informações sem a atribuição da classificação correta. Na fase de avaliação, o modelo é comparado com os dados de teste e os resultados são gerados. Portanto, os algoritmos de ML aprendem através de repetidas observações e estabelecem um padrão de mapeamento com o intuito de rotular os dados e criar um modelo que generaliza as informações, de modo que novos dados (jamais analisados pelo algoritmo) possam ser rotulados com precisão e confiabilidade.

A inteligência artificial (IA) abrange um conjunto de tecnologias que

incluem, mas não se limitam, à aprendizagem de máquina, processamento da linguagem natural, redes neurais e sistemas especializados baseados em regras. Na medicina, costuma ser empregada, por exemplo, para avaliar risco de início de doenças e potenciais resultados de tratamento, aliviar ou reduzir complicações médicas, investigação clínica e desenvolvimento de medicamentos e no cuidado ao paciente (Becker, 2019). O uso de IA em medicina constitui um negócio em crescimento, com mais de seis bilhões de dólares em investimentos esperados para 2021 (HE, 2019).

- **Técnicas de Machine Learning para Diagnóstico Médico**

O uso de técnicas de Machine Learning (ML) no diagnóstico médico tem se expandido rapidamente, possibilitando avanços significativos na precisão e velocidade dos diagnósticos (TOPOL, 2019). Essas técnicas podem analisar grandes volumes de dados clínicos e de imagem, identificando padrões complexos que podem ser difíceis de detectar por métodos tradicionais.

- **Algoritmos Supervisionados**

Para Stair & Reynolds (2006, p.17), os algoritmos supervisionados, como as redes neurais, as máquinas de vetor de suporte (SVM) e as florestas aleatórias, são amplamente utilizados em diagnósticos médicos. Esses algoritmos são treinados em conjuntos de dados rotulados, onde o resultado desejado (por exemplo, a presença ou ausência de uma doença) é conhecido.

- **Redes Neurais Artificiais (ANNs):** As ANNs têm sido usadas para diagnósticos em diversas áreas médicas, incluindo a detecção de doenças cardíacas, câncer e doenças neurológicas.
- **Máquinas de Vetor de Suporte (SVM):** As SVMs são eficazes em problemas de classificação e têm sido aplicadas no diagnóstico de doenças como o câncer de mama e a diabetes. torna particularmente

úteis em conjuntos de dados médicos com muitas variáveis" .

- **Algoritmos Não Supervisionados**

Os algoritmos não supervisionados, como a análise de agrupamento e a redução de dimensionalidade, são usados para explorar estruturas subjacentes nos dados sem a necessidade de rótulos pré-definidos (STAIR & REYNOLDS, 2006).

- **Análise de Agrupamento (Clustering):** Técnicas de agrupamento como o k-means e o DBSCAN, podem identificar subgrupos de pacientes com características similares, ajudando a personalizar tratamentos.
- **Redução de Dimensionalidade:** Métodos como a Análise de Componentes Principais (PCA) e o t-SNE ajudam a simplificar dados de alta dimensionalidade, tornando-os mais manejáveis para análise.
- **Redes Neurais Convolucionais (CNNs):** As CNNs são particularmente eficazes na análise de imagens médicas, como ressonâncias magnéticas e tomografias computadorizadas. Elas têm demonstrado grande precisão na detecção de tumores, lesões e outras anomalias cerebrais.
- **Aplicação em Neuroimagem:** As CNNs podem automatizar a segmentação de estruturas cerebrais e a detecção de anomalias.

- **Aprendizado de Máquina Profundo (Deep Learning)**

O deep learning, uma subcategoria do ML, utiliza redes neurais profundas para aprender representações de dados em múltiplas camadas, o que permite a modelagem de relações altamente complexas (LOPES, 2008).

- **Deteção de Doenças Neurológicas:** O deep learning tem sido aplicado com sucesso na detecção precoce de doenças

neurodegenerativas.


- **Criação do neurônio artificial**

De acordo com Poole (1998, p.22) o primeiro neurônio matemático (também chamado de artificial) que foi modelado foi chamado de Perceptron. A ideia de criação desse neurônio foi modelar uma unidade lógica de processamento que recebesse diferentes sinais em sua entrada; essa unidade iria decidir se soltaria, na saída, o sinal 1 ou a informação 0, tendo o conceito de estar disparado (ativado), ou não estar disparado (desativado).

Esse conceito de modelagem do Perceptron tentava imitar, de certa forma, o conceito que se tinha até então de neurônio biológico: o neurônio estaria ativado ou desativado. Ou seja, a célula estaria mandando informação (impulsos elétricos) para outros neurônios, ou ela não estaria enviando informação.

Figura 1. Representação da Rede do Neurônio

NEURÔNIO



Fonte: Poole (1998).

O conceito que se tinha do cérebro humano, até aquele momento, era o seguinte: determinados neurônios estariam recebendo informação de outros neurônios; eles decidiriam, a partir dessas entradas, se ativariam informações para os outros ou não.

Na realidade, descobriu-se que os mecanismos de funcionamento do cérebro são muito mais complexos que isso: não se resumem apenas às células estarem ativas ou inativas; não é apenas uma questão binária de

mandar, ou não, informação.

- **Inteligência Artificial na Medicina**

Na medicina, o impacto da IA pode verificar-se em três níveis: para os profissionais de saúde, predominantemente por potenciar uma interpretação de imagens mais rápida e precisa; para o sistema de saúde, melhorando o fluxo de trabalho e reduzir o erro médico; e para o paciente, permitindo-lhes o processamento da sua própria informação para promover saúde (BARONE, 2003).

Desta forma, no futuro, quase todos os clínicos nas mais diversas especialidades vão usar este tipo de tecnologia, em particular aprendizagem profunda uma vez que esta capacidade de reconhecimento de padrões através de redes neuronais profundas pode ajudar a interpretar exames médicos, imagens de anatomia patológica, lesões da pele, imagens da retina, eletrocardiogramas, endoscopias, faces, sinais vitais entre outros. Uma especialidade que tem particularmente evoluído com a ajuda de IA é a radiologia, isto porque esta tecnologia ajuda maioritariamente com as tarefas de reconhecimento de imagem através de técnicas de processamento de imagem e visão computacional para que o diagnóstico seja mais rápido, a visualização de patologias seja mais clara, situações de emergência sejam alertadas e a falta de mão-de-obra crítica seja colmatada. Assim, DNN já foram aplicadas numa série de exames médicos como: radiografias ósseas para avaliação de fraturas e idade óssea; tomografia computadorizada (TC) para avaliação de fraturas compressivas vertebrais ou massas hepáticas; TC crânio-encefálica (TC-CE) para avaliação de hemorragia ou traumatismo craniano; eco cardiogramas e mamografias.

- **Processamento de Imagens Médicas**

O processamento de imagens médicas é uma área essencial na medicina moderna, fornecendo ferramentas avançadas para a análise, visualização e interpretação de dados de imagem. Essas técnicas são fundamentais para o diagnóstico, planeamento de tratamento e

monitoramento de diversas condições médicas, incluindo doenças cerebrais.

- **Aquisição de Imagens Médicas**

A aquisição de imagens médicas envolve a captura de dados utilizando diferentes modalidades de imagem, como ressonância magnética (MRI), tomografia computadorizada (CT), ultrassom e tomografia por emissão de pósitrons (PET). Cada modalidade tem suas próprias vantagens e limitações, e a escolha depende do tipo de informação necessária para o diagnóstico (BARONE, 2003).

- **Ressonância Magnética (MRI):** A MRI é amplamente utilizada para obter imagens detalhadas do cérebro e outras estruturas internas.
- **Tomografia Computadorizada (CT):** A CT é eficaz na visualização de ossos e tecidos densos, sendo frequentemente utilizada em emergências para avaliar lesões cerebrais agudas.

- **Pré-processamento de Imagens**

O pré-processamento de imagens é uma etapa crucial para melhorar a qualidade das imagens e preparar os dados para análise subsequente. Isso inclui a remoção de ruído, correção de artefatos e normalização das imagens.

- **Remoção de Ruído:** Técnicas de filtragem, como o filtro de mediana e o filtro de Wiener, são utilizadas para reduzir o ruído nas imagens médicas.
- **Correção de Artefatos:** Artefatos de movimento e distorções podem ser corrigidos utilizando técnicas como a registo de imagens, que alinha múltiplas imagens para reduzir discrepâncias.

- **Segmentação de Imagens**

A segmentação de imagens envolve a identificação e delimitação de

regiões de interesse dentro de uma imagem, como tumores, lesões ou estruturas anatômicas específicas. Essa etapa é crítica para a análise quantitativa e a visualização detalhada das imagens médicas (RAJA; MANOGARAN; LÓPEZ, 2019).

- **Métodos Baseados em Limiares:** A segmentação baseada em limiares é uma técnica simples e eficaz para separar regiões de interesse com base na intensidade dos pixels.
- **Métodos Baseados em Contornos:** Técnicas como o modelo ativo de contornos (snakes) utilizam contornos ativos que se ajustam às bordas dos objetos dentro da imagem.
- **Segmentação de Imagens Médicas**

A segmentação de imagens médicas é uma etapa crucial no processamento de imagens, permitindo a identificação e delimitação de estruturas anatômicas ou patológicas relevantes para diagnóstico e tratamento (RAJA; MANOGARAN; LÓPEZ, 2019, p.36).

A segmentação de imagens médicas desempenha um papel fundamental na extração de informações relevantes para o diagnóstico e tratamento de uma variedade de condições médicas, particularmente no contexto das doenças cerebrais. Essa técnica envolve a subdivisão de uma imagem em regiões ou estruturas anatômicas distintas, permitindo uma análise mais precisa e detalhada.

No caso das doenças cerebrais, como tumores, aneurismas, acidentes vasculares cerebrais (AVCs) e doenças neurodegenerativas, a segmentação precisa das estruturas cerebrais afetadas é crucial para várias etapas do processo clínico:

- **Diagnóstico Diferencial:** A segmentação ajuda os radiologistas e neurologistas a identificar e caracterizar lesões ou anormalidades no cérebro, permitindo o diagnóstico diferencial entre diferentes

condições patológicas. Por exemplo, na presença de um tumor cerebral, a segmentação pode distinguir entre áreas tumorais, edema peritumoral e tecido cerebral saudável.

- **Planejamento Cirúrgico:** Para intervenções cirúrgicas no cérebro, a segmentação pré-operatória das estruturas cerebrais permite a avaliação detalhada da localização, extensão e relação das lesões com regiões críticas, como áreas motoras ou sensoriais, melhorando a precisão e segurança do procedimento.
- **Monitoramento da Progressão da Doença:** A segmentação longitudinal de imagens cerebrais ao longo do tempo possibilita o acompanhamento da progressão de doenças, como o crescimento de tumores, a evolução de lesões isquêmicas após um AVC ou a atrofia cerebral em doenças neurodegenerativas como o Alzheimer.
- **Avaliação de Resposta ao Tratamento:** Ao comparar imagens pré e pós-tratamento, a segmentação permite a avaliação objetiva da resposta do paciente à terapia, como a redução do volume tumoral após a quimioterapia ou a recuperação de áreas isquêmicas após a administração de terapia trombolítica.
- **Deteção de Anomalias**

A detecção de anomalias em imagens médicas, como tomografias computadorizadas (TC) ou ressonâncias magnéticas (RM) cerebrais, é crucial para identificar sinais de patologias, como lesões, tumores, hemorragias ou outras condições anômalas (BELIC, 2019). Aqui estão algumas abordagens comuns:

- **Métodos de Aprendizado Profundo (Deep Learning):**
 - O uso de redes neurais convolucionais (CNNs) tem se mostrado altamente eficaz na detecção de anomalias em

imagens médicas.

- Por exemplo, em um estudo, Jha (2020) utilizaram uma CNN para detectar hemorragias intracranianas em imagens de TC, alcançando resultados promissores em termos de sensibilidade e especificidade.
- **Aprendizado Semi-Supervisionado:**
 - Em situações em que os dados rotulados são escassos, técnicas de aprendizado semi-supervisionado podem ser aplicadas para treinar modelos de detecção de anomalias.
 - Xue (2019) exploraram uma abordagem semi-supervisionada baseada em autoencoders para detectar anomalias em imagens cerebrais, demonstrando sua eficácia na identificação de lesões.
- **Abordagens Baseadas em Transfer Learning:**
 - Transferir conhecimento de modelos pré-treinados em conjuntos de dados grandes para tarefas de detecção de anomalias pode ser benéfico, especialmente quando os dados de treinamento são limitados.
 - Por exemplo, Shin (2016) utilizaram uma arquitetura de rede neural baseada em CNN pré-treinada para detectar diversas anomalias em imagens de raio-X, alcançando resultados competitivos.
- **Métodos de Processamento de Imagem Convencional:**
 - Além das abordagens baseadas em aprendizado de máquina, técnicas clássicas de processamento de imagem, como limiarização, detecção de bordas e morfologia matemática,

também são empregadas na detecção de anomalias.

- **Predição de Progressão da Doença**

A predição da progressão da doença cerebral é uma área de pesquisa crucial que visa antecipar a evolução de condições neurológicas ao longo do tempo. Aqui estão algumas abordagens profundas e citações relevantes:

- **Modelagem Baseada em Agentes**

A abordagem de modelagem baseada em agentes é uma técnica poderosa que trata o cérebro como um sistema complexo, onde cada componente individual, como neurônios ou regiões cerebrais, é representado como um agente autônomo (MELONI, 2020). Essa abordagem permite simular interações dinâmicas entre os agentes, refletindo os princípios fundamentais da atividade neural emergente. Os modelos baseados em agentes são capazes de capturar padrões complexos de atividade cerebral, incluindo sincronização neural, formação de padrões espaciais e propagação de ondas de excitação (DECO, 2008).

Uma das vantagens da modelagem baseada em agentes é sua capacidade de fornecer uma visão detalhada e dinâmica da atividade neural. Ao simular o comportamento de cada agente ao longo do tempo, os pesquisadores podem investigar como pequenas alterações em nível microscópico podem afetar a dinâmica global do sistema. Além disso, esses modelos podem ser usados para explorar como fatores externos, como estimulação elétrica ou drogas neuroativas, influenciam a atividade cerebral e o comportamento emergente do sistema.

No entanto, a modelagem baseada em agentes também apresenta desafios significativos. Um dos principais desafios é a calibração dos parâmetros do modelo, que muitas vezes são desconhecidos ou difíceis de determinar a partir de dados experimentais (DECO, 2008). Além disso, a complexidade computacional envolvida na simulação de grandes redes neurais pode ser proibitivamente alta, exigindo recursos computacionais

significativos (IZHIKEVICH, 2004).

Apesar desses desafios, a modelagem baseada em agentes continua sendo uma ferramenta valiosa para entender os princípios fundamentais da atividade cerebral e investigar como perturbações nesse sistema podem levar ao desenvolvimento de doenças neurológicas (DECO, 2008). Com o avanço da tecnologia computacional e a disponibilidade de novos métodos de simulação, espera-se que essa abordagem continue a desempenhar um papel importante no avanço da neurociência computacional.

- **Aprendizado por Reforço**

O aprendizado por reforço é uma técnica de aprendizado de máquina que se baseia na interação de um agente com um ambiente para aprender ações que maximizam uma recompensa acumulada (BRAGA, 2019). No contexto da progressão de doenças cerebrais, o aprendizado por reforço pode ser aplicado para adaptar dinamicamente estratégias terapêuticas com base nas respostas individuais do paciente ao longo do tempo.

Uma das principais vantagens do aprendizado por reforço é sua capacidade de aprender com feedbacks obtidos por meio da interação com o ambiente. Isso permite que o modelo se adapte a mudanças nas condições do paciente e otimize continuamente as decisões terapêuticas para alcançar os melhores resultados possíveis. Além disso, o aprendizado por reforço pode levar a estratégias terapêuticas mais personalizadas, levando em consideração as características individuais do paciente e sua resposta ao tratamento (BRAGA, 2019).

No entanto, a aplicação do aprendizado por reforço na prática clínica também apresenta desafios significativos. Um dos principais desafios é a necessidade de coletar feedbacks precisos e confiáveis sobre as consequências das ações terapêuticas. Além disso, a segurança e a ética do

uso de algoritmos de aprendizado por reforço em ambientes clínicos devem ser cuidadosamente consideradas, especialmente quando se trata de tomar decisões que afetam diretamente a saúde do paciente.

Apesar desses desafios, o aprendizado por reforço tem o potencial de transformar a prática clínica, permitindo estratégias terapêuticas mais adaptáveis e personalizadas para pacientes com doenças cerebrais. Com o avanço da pesquisa em aprendizado de máquina e a coleta de dados clínicos de alta qualidade, espera-se que essa abordagem desempenhe um papel cada vez mais importante no tratamento de doenças neurológicas.

- **Modelagem Baseada em Fenômenos Físicos**

A modelagem baseada em fenômenos físicos é uma abordagem que utiliza princípios físicos fundamentais para entender a dinâmica da progressão de doenças cerebrais. Por exemplo, modelos de fluxo de líquido cefalorraquidiano podem ser usados para simular o transporte de proteínas patogênicas no cérebro e prever seu impacto na progressão da doença (MONARD, 2000). Esses modelos incorporam propriedades físicas do sistema nervoso central, como viscosidade do fluido e geometria do espaço subaracnóideo, para fornecer insights sobre os mecanismos subjacentes à progressão de doenças neurodegenerativas.

Uma das principais vantagens da modelagem baseada em fenômenos físicos é sua capacidade de fornecer uma compreensão quantitativa e mecanicista da dinâmica da doença. Ao considerar as forças físicas que regem o transporte de biomarcadores patogênicos, esses modelos podem prever como a progressão da doença pode ser afetada por fatores como pressão intracraniana, fluxo sanguíneo cerebral e características anatômicas individuais. Isso pode fornecer informações valiosas para o desenvolvimento de intervenções terapêuticas direcionadas, como terapias de drenagem de líquido cefalorraquidianas ou dispositivos de estimulação cerebral profunda.

No entanto, a modelagem baseada em fenômenos físicos também apresenta desafios significativos. Um dos principais desafios é a

complexidade do sistema nervoso central, que envolve uma ampla gama de fenômenos físicos e biológicos interconectados. Modelar esses fenômenos de forma precisa e abrangente requer uma compreensão detalhada das propriedades físicas do cérebro e suas interações com o ambiente circundante.

Apesar desses desafios, a modelagem baseada em fenômenos físicos continua sendo uma ferramenta valiosa para entender os mecanismos subjacentes à progressão de doenças cerebrais e desenvolver estratégias terapêuticas eficazes. Com o avanço da tecnologia de simulação e a disponibilidade de dados clínicos de alta qualidade, espera-se que essa abordagem desempenhe um papel cada vez mais importante no tratamento de doenças neurológicas.

- **Análise de Texturas e Padrões Complexos**

A análise de texturas e padrões complexos em imagens médicas é uma abordagem que visa extrair informações detalhadas sobre a organização estrutural e funcional do cérebro. Por exemplo, Lopes (2008, p.23) utilizaram uma abordagem baseada em aprendizado profundo para analisar padrões de conectividade funcional em imagens de ressonância magnética funcional e prever o declínio cognitivo em pacientes com doença de Alzheimer. Essa abordagem captura informações sutis sobre a organização funcional do cérebro, que podem ser indicativas de alterações relacionadas à progressão da doença.

Uma das principais vantagens da análise de texturas e padrões complexos é sua capacidade de capturar informações multidimensionais sobre a estrutura e função do cérebro. Ao explorar padrões de conectividade funcional, morfologia cortical ou distribuições de densidade de voxel em imagens médicas, os pesquisadores podem identificar marcadores precoces de doenças cerebrais e desenvolver biomarcadores sensíveis para monitorar sua progressão ao longo do tempo.

No entanto, a análise de texturas e padrões complexos também

apresenta desafios significativos. Um dos principais desafios é a interpretação dos padrões extraídos e sua relação com os processos biológicos subjacentes. Nem todos os padrões observados em imagens médicas podem ser diretamente atribuídos a alterações patológicas específicas, e a validade clínica desses biomarcadores deve ser cuidadosamente avaliada em estudos longitudinais.

Apesar desses desafios, a análise de texturas e padrões complexos continua sendo uma ferramenta valiosa para entender a progressão de doenças cerebrais e desenvolver biomarcadores sensíveis para monitorar sua evolução ao longo do tempo. Com o avanço da tecnologia de imagem e o desenvolvimento de métodos analíticos mais sofisticados, espera-se que essa abordagem desempenhe um papel cada vez mais importante na identificação precoce e no tratamento de doenças neurológicas.

- **Integração de Dados Multimodais**

A integração de dados multimodais é uma abordagem poderosa que combina informações de diferentes fontes, como imagens médicas, dados genéticos, biomarcadores clínicos e informações comportamentais, para fornecer uma compreensão mais abrangente da progressão de doenças cerebrais (BARONE, 2003). Ao integrar múltiplos tipos de dados, os pesquisadores podem capturar aspectos complementares da patologia cerebral, fornecendo insights valiosos sobre os mecanismos subjacentes à doença e identificando potenciais alvos terapêuticos.

Uma das principais vantagens da integração de dados multimodais é sua capacidade de compensar as limitações de cada modalidade individualmente. Por exemplo, enquanto imagens de ressonância magnética podem fornecer informações detalhadas sobre a anatomia cerebral, dados genéticos podem revelar predisposições genéticas para certas condições neurológicas. Ao combinar essas informações, os pesquisadores podem identificar subgrupos de pacientes com características genéticas específicas que estão em maior risco de desenvolver a doença e adaptar estratégias

terapêuticas para atender às suas necessidades.

No entanto, a integração de dados multimodais também apresenta desafios significativos. Um dos principais desafios é a heterogeneidade dos dados, que podem variar em escala, resolução, precisão e confiabilidade. Além disso, a integração de dados de diferentes fontes pode introduzir vieses ou ruídos que podem afetar a precisão das análises. Portanto, é crucial desenvolver métodos robustos de integração de dados que levem em consideração essas variações e garantam resultados confiáveis e reproduzíveis.

Para superar esses desafios, os pesquisadores têm explorado uma variedade de técnicas de integração de dados multimodais, incluindo métodos baseados em redes, análise de componentes principais e aprendizado por transferência. Essas abordagens buscam identificar padrões comuns ou correlações entre diferentes modalidades de dados, permitindo a construção de modelos preditivos mais precisos e robustos.

- **Interpretabilidade do Modelo**

A interpretabilidade do modelo é um aspecto crucial ao lidar com o desenvolvimento de inteligência artificial para o diagnóstico de doenças cerebrais. Embora modelos complexos, como redes neurais profundas, possam oferecer alta precisão na previsão de diagnósticos, sua falta de interpretabilidade pode ser uma barreira significativa para sua adoção clínica (BARONE, 2003). Portanto, garantir que os modelos sejam interpretáveis é essencial para que os médicos entendam e confiem nas decisões tomadas pelo sistema de IA.

Existem várias abordagens para aumentar a interpretabilidade dos modelos de IA aplicados ao diagnóstico de doenças cerebrais. Uma abordagem comum é o uso de modelos interpretáveis, como árvores de decisão ou regressão linear, em vez de modelos de caixa preta mais complexa. Embora esses modelos possam ter desempenho ligeiramente inferior em termos de precisão, sua interpretabilidade os torna mais

aceitáveis para uso clínico, pois os médicos podem entender facilmente como as decisões são tomadas.

Além disso, técnicas de interpretabilidade específicas podem ser aplicadas a modelos de caixa preta para fornecer insights sobre como eles tomam decisões. Por exemplo, a análise de saliência pode ser usada para identificar quais características de entrada foram mais importantes para a decisão final do modelo. Isso pode ajudar os médicos a entender o raciocínio por trás das previsões do modelo e identificar possíveis pontos fracos ou vieses nos dados.

Outra abordagem para aumentar a interpretabilidade é fornecer explicações naturais para as previsões do modelo. Por exemplo, em vez de apenas fornecer uma previsão de diagnóstico, o sistema de IA pode explicar em linguagem natural quais características foram consideradas importantes para essa previsão e como elas se relacionam com o diagnóstico final. Isso permite que os médicos entendam facilmente o raciocínio por trás das decisões do modelo e forneçam insights adicionais sobre o caso clínico.

- **Transfer Learning**

Transfer Learning é uma técnica de aprendizado de máquina que tem sido amplamente adotada em uma variedade de aplicações, incluindo o diagnóstico de doenças cerebrais, devido à sua capacidade de aproveitar o conhecimento adquirido em uma tarefa para melhorar o desempenho em outra tarefa relacionada. Em contextos médicos, onde a disponibilidade de dados rotulados pode ser limitada e a generalização é essencial, o Transfer Learning pode desempenhar um papel fundamental na criação de modelos de IA robustos e precisos.

Uma das formas mais comuns de Transfer Learning é o uso de redes neurais convolucionais pré-treinadas em grandes conjuntos de dados de imagens, como o ImageNet, como base para tarefas de classificação de imagens médicas (SHIN, 2016). Esses modelos pré-treinados já aprenderam a extrair características relevantes de imagens naturais e podem ser

finamente ajustados com conjuntos de dados médicos menores para tarefas específicas, como a detecção de tumores cerebrais em imagens de ressonância magnética.

Além disso, o Transfer Learning pode ser aplicado não apenas na camada de características de um modelo, mas também em camadas mais profundas, permitindo que o modelo adapte não apenas as características de baixo nível, como bordas e texturas, mas também representações mais abstratas e contextuais. Isso é particularmente útil em tarefas complexas, como a segmentação de estruturas cerebrais em imagens médicas, onde a representação de características semânticas é crucial para o desempenho do modelo.

No entanto, a aplicação bem-sucedida do Transfer Learning em diagnósticos médicos requer considerações cuidadosas sobre a escolha do modelo pré-treinado e a estratégia de ajuste fino. Nem todos os modelos pré-treinados são igualmente adequados para todas as tarefas, e é importante selecionar um modelo que capture efetivamente as características relevantes para a tarefa específica em questão. Além disso, o ajuste fino excessivo pode levar à memorização dos dados de treinamento e à redução da capacidade de generalização do modelo, destacando a importância de técnicas de regularização eficazes para evitar overfitting.

Outro desafio importante é a heterogeneidade dos dados médicos, que podem variar em modalidade, qualidade e protocolo de aquisição. Isso pode dificultar a transferência de conhecimento de um conjunto de dados para outro e exigir técnicas de adaptação de domínio para ajustar o modelo aos novos dados de destino (ZHANG, 2021). Essas técnicas buscam minimizar a diferença de distribuição entre os dados de origem e de destino, permitindo que o modelo generalize de forma mais eficaz para novos casos.

- **Avaliação da Incerteza**

A avaliação da incerteza é uma consideração crítica no desenvolvimento de modelos de inteligência artificial para o diagnóstico de

doenças cerebrais. A incerteza surge de várias fontes, incluindo a variabilidade dos dados, a complexidade dos modelos e a aleatoriedade inerente aos processos biológicos. Portanto, compreender e quantificar a incerteza associada às previsões do modelo é essencial para uma interpretação precisa e confiável dos resultados.

Uma abordagem comum para avaliar a incerteza é a utilização de métodos de Monte Carlo, onde múltiplas amostras são geradas a partir da distribuição de parâmetros do modelo para capturar a variabilidade nos resultados. Essas amostras podem ser usadas para estimar intervalos de confiança para as previsões do modelo, fornecendo uma medida quantitativa da incerteza associada a cada diagnóstico.

Técnicas como a *debootstrap* ou a validação cruzada podem ser empregadas para avaliar a robustez das previsões do modelo em relação à variabilidade dos dados de treinamento. Essas abordagens envolvem a reamostragem dos dados de treinamento múltiplas vezes para gerar estimativas distribuídas da precisão do modelo, permitindo uma avaliação mais abrangente da incerteza.

Outra estratégia importante é o uso de modelos probabilísticos, como redes neurais Bayesianas, que são capazes de representar explicitamente a distribuição de incerteza sobre as previsões do modelo (Blundell et al., 2015). Esses modelos fornecem uma estrutura formal para a avaliação da incerteza, permitindo que os médicos avaliem a confiabilidade das previsões do modelo e tomem decisões informadas com base nessa informação.

No entanto, a avaliação da incerteza em modelos de IA para diagnóstico de doenças cerebrais também apresenta desafios significativos. Um dos principais desafios é a escolha adequada do método de avaliação da incerteza, que deve levar em consideração a natureza específica dos dados e do problema em questão (CHOI, 2018). Além disso, a interpretação e comunicação da incerteza aos clínicos e pacientes requerem habilidades de comunicação eficazes para garantir que as informações sejam compreendidas e utilizadas de forma apropriada.

avaliação da incerteza desempenha um papel fundamental no desenvolvimento de modelos de IA para diagnóstico de doenças cerebrais. Ao compreender e quantificar a incerteza associada às previsões do modelo, os médicos podem tomar decisões mais informadas e confiáveis, garantindo uma prática clínica segura e eficaz. No entanto, é importante enfrentar os desafios associados à escolha e interpretação dos métodos de avaliação da incerteza para garantir resultados confiáveis e clinicamente úteis.

- **Privacidade e Segurança dos Dados**

A privacidade e a segurança dos dados são preocupações fundamentais no desenvolvimento de sistemas de inteligência artificial (IA) para o diagnóstico de doenças cerebrais, especialmente quando lidamos com dados médicos sensíveis. Proteger a privacidade dos pacientes e garantir a segurança dos dados é essencial para construir confiança na aplicação desses sistemas na prática clínica e na pesquisa médica. Portanto, é crucial adotar abordagens robustas e eficazes para mitigar os riscos de violações de privacidade e ataques cibernéticos.

Uma abordagem fundamental para proteger a privacidade dos dados é a utilização de técnicas de anonimização e pseudonimização. Essas técnicas visam remover ou substituir informações identificáveis dos dados médicos, preservando ao mesmo tempo sua utilidade para fins de pesquisa e diagnóstico (El Emam et al., 2006). Ao ocultar a identidade dos pacientes nos conjuntos de dados, os riscos de reidentificação e violação de privacidade são reduzidos significativamente.

Além disso, a criptografia é uma ferramenta poderosa para garantir a segurança dos dados médicos durante o armazenamento e a transmissão. A criptografia de ponta a ponta, por exemplo, protege os dados enquanto estão em trânsito, garantindo que apenas os destinatários autorizados possam acessá-los (KAUARK, 2010). Da mesma forma, a criptografia de dados em repouso protege as informações armazenadas nos sistemas de banco de dados contra acessos não autorizados.

Outra consideração importante é a implementação de medidas de controle de acesso, que garantem que apenas indivíduos autorizados possam acessar os dados médicos sensíveis. Isso pode ser alcançado por meio da implementação de sistemas de autenticação robustos, como a autenticação de dois fatores, e da atribuição de privilégios de acesso com base no princípio do mínimo. Ao restringir o acesso apenas a profissionais de saúde autorizados, os riscos de acesso não autorizado são mitigados.

No entanto, apesar dessas medidas de segurança, os sistemas de IA para o diagnóstico de doenças cerebrais também enfrentam desafios únicos em relação à privacidade e segurança dos dados. Por exemplo, modelos de IA muitas vezes exigem grandes quantidades de dados para treinamento, o que pode aumentar os riscos de violação de privacidade e reidentificação. Além disso, a natureza complexa e não interpretável dos modelos de IA pode dificultar a identificação e mitigação de vieses e discriminação nos resultados.

Portanto, é essencial adotar uma abordagem holística e multidisciplinar para abordar questões de privacidade e segurança dos dados em sistemas de IA para diagnóstico de doenças cerebrais. Isso envolve a colaboração entre especialistas em IA, segurança da informação, ética médica e legislação de proteção de dados para desenvolver políticas e práticas robustas que garantam a privacidade e segurança dos pacientes, ao mesmo tempo em que promovem avanços significativos na medicina personalizada e diagnóstica de doenças cerebrais.

- **Aplicativos Clínicos e Implantação**

A integração de aplicativos clínicos baseados em inteligência artificial (IA) para o diagnóstico de doenças cerebrais apresenta oportunidades significativas para melhorar a eficiência e a precisão dos cuidados médicos. No entanto, sua implantação eficaz requer considerações abrangentes, desde a validação clínica até a integração com os fluxos de trabalho existentes. Neste contexto, citações diretas podem destacar as melhores

práticas e desafios enfrentados pelos profissionais de saúde e pesquisadores.

Um estudo recente de Johnson (2020, p.30) enfatizou a importância de uma abordagem iterativa e colaborativa na implantação de aplicativos clínicos baseados em IA. Os autores destacaram que a coleta de feedback constante dos clínicos e dos usuários finais é essencial para garantir que os aplicativos atendam às necessidades clínicas e sejam integrados com sucesso aos fluxos de trabalho existentes. Essa abordagem centrada no usuário é fundamental para promover a aceitação e adoção dos aplicativos no ambiente clínico.

A validação clínica rigorosa é um passo crítico na implantação de aplicativos clínicos baseados em IA. Como observado por (RUSSELL e NORVIG, 2019), a validação em larga escala em diferentes contextos clínicos e populações de pacientes é essencial para garantir a segurança e eficácia dos aplicativos. Isso envolve a realização de estudos prospectivos e retrospectivos para avaliar o desempenho do aplicativo em condições do mundo real e compará-lo com o padrão ouro atual.

No entanto, a implantação de aplicativos clínicos baseados em IA também enfrenta desafios significativos, incluindo questões relacionadas à interoperabilidade, regulamentação e segurança dos dados. Como observado por Saria (2021), garantir a interoperabilidade dos aplicativos com os sistemas de registros médicos eletrônicos (EMRs) existentes é crucial para facilitar a integração e adoção pelos clínicos. Isso requer a implementação de padrões de interoperabilidade e interfaces bem definidas para permitir a troca eficiente de dados entre os sistemas.

A regulamentação de aplicativos clínicos baseados em IA é uma área em evolução que requer uma abordagem equilibrada para garantir a segurança dos pacientes sem sufocar a inovação. Conforme destacado por (ALEXANDER, 2020), a Food and Drug Administration (FDA) nos Estados Unidos e agências reguladoras em outros países estão trabalhando para desenvolver diretrizes claras e processos de aprovação para aplicativos de IA

na área da saúde. No entanto, a complexidade e a rápida evolução da tecnologia apresentam desafios únicos para os reguladores.

A implantação de aplicativos clínicos baseados em IA para o diagnóstico de doenças cerebrais oferece oportunidades emocionantes para melhorar os cuidados médicos. No entanto, essa implantação requer uma abordagem cuidadosa e colaborativa, que inclui validação clínica rigorosa, integração com fluxos de trabalho existentes e considerações regulatórias e de segurança de dados. Ao abordar esses desafios de forma proativa e colaborativa, podemos maximizar o potencial dos aplicativos de IA para melhorar os resultados dos pacientes e promover avanços significativos na medicina.

- **Requisitos**

Para a implantação bem-sucedida de aplicativos clínicos baseados em inteligência artificial (IA) para o diagnóstico de doenças cerebrais, diversos requisitos devem ser considerados. Esses requisitos abrangem desde aspectos técnicos e clínicos até questões regulatórias e éticas. Abaixo, destaco alguns dos principais requisitos a serem considerados:

Validação Clínica Rigorosa: Antes da implantação, os aplicativos clínicos baseados em IA devem passar por uma validação clínica rigorosa para garantir sua precisão e segurança. Isso envolve a realização de estudos clínicos prospectivos e retrospectivos em diferentes contextos clínicos e populações de pacientes.

Interoperabilidade com Sistemas de Registros Médicos Eletrônicos (EMRs): Os aplicativos de IA devem ser capazes de interoperar de forma eficiente com os sistemas de EMR existentes para permitir a troca segura de dados entre os aplicativos e os registros médicos eletrônicos dos pacientes.

Segurança e Privacidade dos Dados: Medidas robustas de segurança e privacidade dos dados devem ser implementadas para proteger

as informações sensíveis dos pacientes contra acesso não autorizado e violações de segurança.

Integração com Fluxos de Trabalho Clínicos: Os aplicativos de IA devem ser integrados de forma transparente aos fluxos de trabalho clínicos existentes, garantindo que sejam usados de maneira eficaz pelos profissionais de saúde no dia a dia.

Transparência e Interpretabilidade: Os algoritmos de IA utilizados nos aplicativos clínicos devem ser transparentes e interpretáveis, permitindo que os clínicos entendam como as decisões são tomadas e confiem nos resultados fornecidos pelo sistema.

Regulamentação e Conformidade: Os aplicativos de IA devem cumprir as regulamentações e padrões éticos relevantes, como a Lei Geral de Proteção de Dados (LGPD) e os requisitos da Food and Drug Administration (FDA) nos Estados Unidos, para garantir a segurança e eficácia dos aplicativos.

Treinamento e Educação: Os profissionais de saúde que utilizarão os aplicativos de IA devem receber treinamento adequado para entender como usar as ferramentas de forma eficaz e interpretar corretamente os resultados fornecidos pelo sistema.

Suporte Técnico e Manutenção: É necessário fornecer suporte técnico contínuo e manutenção dos aplicativos de IA após a implantação para garantir seu bom funcionamento e resolver quaisquer problemas que possam surgir.

Ao atender a esses requisitos de forma abrangente e cuidadosa, é possível garantir uma implantação bem-sucedida de aplicativos clínicos baseados em IA para o diagnóstico de doenças cerebrais, contribuindo para uma prática clínica mais eficiente e resultados melhores para os pacientes.

- **Importância da IA no diagnóstico das doenças neurais**

Lobo (2017) afirma que a inteligência artificial (IA) desempenha um papel cada vez mais crucial no diagnóstico das doenças neurais, proporcionando benefícios significativos tanto para pacientes quanto para profissionais de saúde. A importância da IA nesse contexto pode ser destacada em várias frentes:

- **Deteção de Padrões Complexos**

A detecção de padrões complexos é uma das áreas em que a inteligência artificial (IA) se destaca no diagnóstico de doenças neurais. Esta capacidade é fundamental, uma vez que muitas condições neurológicas apresentam padrões sutis e multifacetados que podem ser difíceis de identificar por métodos tradicionais. A IA, por sua vez, pode analisar grandes conjuntos de dados e reconhecer correlações e padrões que podem passar despercebido aos olhos humanos (LOBO, 20017, p.34).

Um dos benefícios mais marcantes da detecção de padrões complexos por meio da IA é a capacidade de lidar com grandes volumes de informações de forma eficiente e sistemática. Essa capacidade é particularmente útil em imagens médicas, como ressonâncias magnéticas e tomografias computadorizadas, onde características sutis podem conter informações diagnósticas vitais. De fato, estudos têm demonstrado que algoritmos de IA podem identificar padrões em imagens médicas que escapam à detecção humana, aumentando assim a sensibilidade do diagnóstico.

Um exemplo notável é o uso de redes neurais convolucionais (CNNs) na interpretação de imagens cerebrais para diagnosticar condições como tumores, lesões traumáticas e doenças neurodegenerativas. As CNNs são especialmente eficazes na detecção de características complexas, como padrões de textura, forma e distribuição de contraste, que podem fornecer pistas importantes sobre a presença e a progressão dessas condições.

Outro exemplo é a análise de padrões em dados genéticos para identificar predisposições genéticas a doenças neurológicas. Algoritmos de

IA podem examinar grandes conjuntos de dados genômicos e identificar correlações entre variantes genéticas específicas e condições neurológicas, auxiliando assim no diagnóstico precoce e no desenvolvimento de terapias personalizadas.

No entanto, é importante reconhecer que a detecção de padrões complexos por meio da IA não é isenta de desafios. Um dos desafios principais é a interpretabilidade dos modelos, ou seja, a capacidade de entender como e por que um determinado padrão foi identificado. A interpretabilidade é crucial para a confiança dos profissionais de saúde nos resultados fornecidos pela IA e para a identificação de possíveis vieses ou erros no processo de detecção de padrões.

- **Detecção de Padrões Complexos**

Segundo Fomenko (2019, p.25), a detecção de padrões complexos é uma das capacidades mais cruciais da inteligência artificial (IA) no diagnóstico de doenças neurais. As condições neurológicas frequentemente apresentam uma variedade de características sutis e multifacetadas, que podem ser desafiadoras de identificar por métodos convencionais. Nesse sentido, a IA se destaca ao analisar grandes conjuntos de dados e identificar correlações e padrões que podem passar despercebidos aos olhos humanos.

Um dos principais benefícios da detecção de padrões complexos pela IA é sua capacidade de processar grandes volumes de informações de forma eficiente e sistemática. Esse recurso é particularmente valioso em imagens médicas, como ressonâncias magnéticas e tomografias computadorizadas, onde características sutis podem conter informações diagnósticas cruciais. Estudos têm demonstrado que algoritmos de IA podem identificar padrões em imagens médicas que podem escapar à detecção humana, aumentando assim a sensibilidade do diagnóstico.

Por exemplo, algoritmos de aprendizado profundo, como redes neurais convolucionais (CNNs), têm se mostrado eficazes na interpretação de

imagens cerebrais para diagnosticar condições como tumores, lesões traumáticas e doenças neurodegenerativas. As CNNs são especialmente habilidosas na detecção de características complexas, como texturas, formas e distribuições de contraste, que podem oferecer insights importantes sobre a presença e a progressão dessas condições.

Outra aplicação significativa é a análise de padrões em dados genéticos para identificar predisposições genéticas a doenças neurológicas. Algoritmos de IA podem examinar grandes conjuntos de dados genômicos e encontrar correlações entre variantes genéticas específicas e condições neurológicas, possibilitando diagnósticos mais precoces e o desenvolvimento de terapias personalizadas (FOMENKO, 2019).

Apesar dos benefícios, a detecção de padrões complexos por meio da IA enfrenta desafios, como a interpretabilidade dos modelos. Compreender como e por que um determinado padrão foi identificado é crucial para a confiança dos profissionais de saúde nos resultados fornecidos pela IA e para identificar possíveis vieses ou erros no processo de detecção de padrões.

- **Auxílio à Tomada de Decisão Clínica**

O auxílio à tomada de decisão clínica é uma das áreas mais promissoras onde a inteligência artificial (IA) tem demonstrado grande potencial no contexto do diagnóstico de doenças neurais. A capacidade da IA de analisar grandes volumes de dados e fornecer insights baseados em evidências pode ajudar os profissionais de saúde a tomar decisões mais informadas e precisas em relação ao diagnóstico e tratamento de pacientes com condições neurológicas complexas (BRAGA, 2019).

Um dos principais benefícios do auxílio à tomada de decisão clínica pela IA é a capacidade de processar e integrar uma ampla gama de informações de forma rápida e eficiente. Isso inclui dados clínicos, como histórico médico, sintomas e resultados de exames, bem como evidências científicas atualizadas e diretrizes de prática clínica (BRAGA, 2019, p.47). Ao

analisar esses dados de maneira abrangente, a IA pode identificar padrões, tendências e associações que podem não ser óbvias para os profissionais de saúde, fornecendo assim insights valiosos para apoiar a tomada de decisão.

Por exemplo, sistemas de IA podem ser treinados para auxiliar na triagem e diagnóstico de condições neurológicas com base em sintomas relatados pelo paciente e resultados de exames clínicos. Esses sistemas podem fornecer recomendações baseadas em evidências sobre quais testes adicionais devem ser realizados ou quais tratamentos são mais adequados para cada paciente com base em sua condição específica e características individuais.

A IA pode ajudar os profissionais de saúde a interpretar e analisar imagens médicas, como ressonâncias magnéticas e tomografias computadorizadas, para identificar anomalias e padrões que possam indicar a presença de doenças neurais. Algoritmos de IA podem destacar áreas de interesse, auxiliando os radiologistas e neurologistas na interpretação dos resultados e no desenvolvimento de planos de tratamento adequados.

O auxílio à tomada de decisão clínica pela IA não substitui a expertise e o julgamento clínico dos profissionais de saúde. Em vez disso, a IA atua como uma ferramenta complementar, fornecendo insights e informações adicionais para apoiar a tomada de decisão compartilhada entre médicos e pacientes.

- **Inteligência artificial e a sua terminologia**

Ao aplicar tecnologia dotada de IA aos pacientes, os médicos não são os que se encontram no banco de trás, mas sim aqueles que se encontram no lugar do condutor uma vez que têm de ser capazes de resolver qualquer ansiedade, confusão e questões que o paciente ou o público possa ter sobre as aplicações de IA na medicina (XU, 2019). Assim, os profissionais de saúde são responsáveis por assegurar que IA se torne numa tecnologia que beneficie o cuidado do doente. Por estas razões, é crucial que adquiram conhecimentos sólidos e experiência nesta área.

Embora IA seja um termo geral que contenha muitas formas de ciência da computação, na medicina podemos focar-nos maioritariamente nos seguintes termos:

- **Processamento de imagem:**

Processo matemático que realça uma imagem para melhorar a clareza, retirar informações específicas ou para medição de padrões. Basicamente o input é uma imagem e o output é uma imagem mais bem definida para um propósito específico.


- **Visão computacional (do inglês computer vision - CV):**

Processamento de uma imagem para permitir a sua identificação e fornecer um output apropriado, ou seja, a interpretação dessa imagem.

- **Redes neuronais (do inglês neural networks):**

As redes neuronais são ferramentas analíticas computacionais inspiradas no sistema nervoso e na sua habilidade em aprender padrões complicados mudando a força das conexões sinápticas entre neurónios. Nas redes neuronais artificiais (ANN, do inglês artificial neural networks), o input é inserido numa série de algoritmos e o output desses algoritmos é reinserido noutro conjunto diferente de algoritmos de maneira a chegar ao output final. Uma rede neuronal profunda (DNN, do inglês deep neuronal network) é quando existe mais do que uma camada “escondida” entre o input e o output e uma rede neuronal convolucional (CNN, do inglês convolutional neural network) é outro tipo específico de ANN, tipicamente baseada em algoritmos de aprendizagem profunda com diversas camadas escondidas para analisar a informação relacionada especificamente com a CV (Figura 2).

Figura 2. Redes neuronais.



Fonte: (XU, 2019).

- **Aprendizagem automática (do inglês machine learning – ML):**

Este termo refere-se à capacidade de um computador aprender por experiência, isto é, modificar a sua maneira de processar baseando-se em informações recémadquiridas.

- **Aprendizagem profunda (do inglês deep learning - DL):**

É um subtipo de aprendizagem automática que usa redes neuronais profundas com múltiplas camadas intermédias de neurónios artificiais entre o input e o output e como o córtex visual, estes neurónios aprendem a hierarquia de características progressivamente mais complexas.

A aprendizagem profunda provocou atração intuitiva pela área da saúde e possíveis aplicações dado à sua robustez no reconhecimento de padrões complexos e construção de modelos preditivos a partir de grandes conjuntos de informação.

- **Aprendizagem profunda não supervisionada:**

Técnicas de clustering para organizar e separar dados em grupos ou padrões ou identificar características mais específicas de conjuntos de dados.

- **Processamento de linguagem natural (NLP, do inglês neural language processing):**

É um subtipo de AI que envolve os métodos algorítmicos supramencionados. Refere-se à maneira como os computadores processam e analisam a linguagem humana que se encontra em textos não estruturados e requer traduções, entendimento semântico e extração de informação.

- **Inteligência artificial aplicada à medicina, no diagnóstico de doenças.**

Desde a Revolução Industrial, a humanidade busca ferramentas para aumentar a sua produtividade e facilitar processos. Com o surgimento da era moderna, uma dessas ferramentas consiste na realização de atividades sem a intervenção humana direta. Após décadas, com a criação desta, que hoje é considerada uma área da ciência da computação, a Inteligência artificial possui a capacidade de simular o raciocínio humano.

A inteligência artificial, no entanto, é uma ciência de difícil definição, e

segundo Paulo Bock, se utiliza da programação de uma máquina para a consecução de um objetivo específico e com isso esse novo sistema poderá aprender com o ambiente tendo como base a tentativa de erro e acerto (BOCK, 1988).

Para Strafella (2018), a Inteligência artificial é um ramo da ciência da computação que se propõe a desenvolver sistemas que simulem a capacidade humana de percepção de um problema, identificando seus componentes para, com isso, resolver problemas e propor/tomar decisões.

Os primórdios da inteligência artificial datam de 1950, quando foi publicado o artigo “Computing Machinery and Intelligence”, de Alan Turing (1950) Nesse artigo, o autor propõe uma dinâmica para testar a performance de um computador e de uma pessoa na resolução de um problema, tal experiência ficou conhecida como teste de Turing.

Posteriormente, John McCarthy e alguns colegas do Dartmouth College foram os responsáveis por criar o termo “Inteligência artificial” em 1956 (2007). Nesse sentido, Sperandio (2018, p. 108) resumiu a evolução da Inteligência artificial:

[...] Em 2004, os robôs Spirits e Opportunity pousaram em Marte e foram capazes de operar autonomamente para compensar o atraso entre a emissão do comando na Terra e sua chegada em Marte por ondas de rádio. Desde 2005, com base no rastreamento de atividades na internet e na mídia, empresas passaram a recomendar produtos que poderiam ser do interesse do usuário. Em 2011, o computador Watson da IBM venceu os campeões Brad Rutter e Ken Jennings no programa de televisão Jeopardy. Em 2015, a frota de carros autônomos da Google já tinha navegado mais de 1,5 milhão de quilômetros, apresentando apenas 14 acidentes (sem que nenhum deles tenha sido por culpa do carro).

Portanto, o principal objetivo da inteligência artificial é tornar as atividades humanas mais práticas e rápidas, sendo inegável que a sua utilização tem se tornado cada dia mais presente nas atividades cotidianas.

Na sequência veremos os principais softwares de Inteligência artificial

voltados ao diagnóstico de doenças da atualidade.

O uso da inteligência artificial teve um aumento exponencial nas últimas décadas, passando a desempenhar um papel fundamental na medicina e sendo implementada em diversas etapas do atendimento médico, dentre elas o diagnóstico de doenças, que em grande parte é realizado pela leitura de exames por imagens. Com isso a classificação dessas imagens pela Inteligência artificial passou a possibilitar a detecção precoce de doenças, além de aprimorar os fluxos de trabalhos, acelerando a leitura desses exames por imagem e priorizando os casos urgentes.

A título de exemplo, o Congresso da Sociedade Americana de Radiologia, em 2018, registrou 237 trabalhos relacionados a inteligência artificial, confirmando que uma das principais aplicações dela na medicina, atualmente, está na análise de imagens médica. Dentre os trabalhos, foram apresentadas soluções que incluem a detecção automática de nódulos pulmonares, pneumonia, pneumotórax e derrame pleural na radiografia simples e de tórax, detecção e quantificação de enfisema além da estimativa do risco de malignidade de nódulo pulmonar, dentre muitos outros. (SANTOS, 2019).

Outro exemplo da utilização da Inteligência artificial na medicina está no diagnóstico de doenças de câncer de pele, doença que no Brasil, segundo o Instituto Nacional do Câncer, corresponde a 33% dos diagnósticos de todos os tipos de câncer. Pesquisadores desenvolveram soluções baseadas em IA utilizando dados públicos de lesões cutâneas para distinguir lesões cutâneas malignas e benignas em imagens dermatoscópicas, clínicas e histopatológicas, alcançando maior precisão na diferenciação das lesões de pele. (GOYAL, 2020).

Além disso, um dos maiores avanços na área é o trabalho de Goyal, que comparou o desempenho de dermatologistas e um método de aprendizado de máquina para diferenciar carcinomas versus ceratoses seborreicas benignas e melanomas versus nevos benignos. O resultado mostrou que o método é compatível com o desempenho das

dermatologistas.

No entanto, pesquisadores afirmam que o desempenho desses sistemas apesar de excederem o desempenho das dermatologistas, no diagnóstico de câncer de pele, estão longe de ser realidade, já que funcionam como experimentos, obedecendo a um conjunto de regras pré-estabelecidas. (GOYAL, 2020).

CAPITULO II: METODOLOGIA DE PESQUISA

Para Lakatos & Marconi (2003), de acordo com a metodologia é uma preocupação instrumental, que trata de o caminho para a ciência tratar a realidade teórica e prática e centram-se, geralmente, no esforço de transmitir uma iniciação procedimentos lógicos voltados para questões da causalidade, dos princípios formais da identidade, da dedução e da indução.

2.1. Tipos de pesquisas

- **Descritiva**

Para o trabalho dissertativo usar-se-á a pesquisa descritiva, que o autor em epígrafe defende ser uma modalidade de pesquisa caracteriza-se em descrever as principais características de um determinado fenómeno em estudo, estabelecendo relações entre as variáveis a serem estudadas.

O motivo da eleição deste tipo de pesquisa é que ela nos permitirá identificar, descrever e relacionar as principais variáveis identificadas neste trabalho, e ajudar-nos-á a compreender melhor a situação a que nos propusemos a estudar.

2.2. Modelo de abordagem

- **Quali-quantitativa**

Para o presente trabalho usar-se-á a abordagem quali-quantitativa. Segundo Gil, (2002) este tipo de abordagem caracteriza-se pela utilização de instrumentos estatísticos, tanto na colecta quanto no tratamento dos dados, ela tem a intenção de garantir a precisão dos resultados, evitar distorções, ao mesmo tempo que procura interpretar os resultados pela via de fundamentações argumentativas.

Achamo-la pertinente, pois, pretende-se quantificar os resultados que obtivermos na pesquisa, ao mesmo tempo que argumentaremos pela via da explicação de como terá surgido cada resultado, com fundamento do porque das suas aparições no quadro de dados.

2.3. Nível de estruturação de método

- **Nível teórico**

Marconi e Lakatos (2008, p. 107) exprimem que o histórico lógico “a compreensão dos fenómenos que ocorrem no sector em termos económicos, técnico e ambiental dependem do conhecimento da evolução histórica.” Esta análise possibilita a identificação da lógica do seu desenvolvimento, o seu

comportamento através do tempo e as perspectivas para o futuro.

- **Nível estatístico - matemático**

Segundo Marconi e Lakatos (2005, p. 108-109), o método estatístico “é o modelo de regressão múltipla, como importantes auxílios para o presente estudo, no que tange o tratamento e análise de dados coletados”. É a tentativa de evidenciar relações existentes entre o fenómeno em estudo e outros fatores.

2.4. Técnica de recolha de dados

Para o trabalho usamos a técnica de entrevista e questionário, fonte de dados: As principais fontes de dados serão os registros médicos e exames clínicos de pacientes angolanos com doenças cerebrais. Além disso, serão utilizadas bases de dados públicas contendo imagens cerebrais, como ressonância magnética e tomografia computadorizada, para o treinamento e validação da IA.

Coleta de dados: Os dados serão coletados de hospitais e clínicas em Angola, em conformidade com as regulamentações de privacidade e ética aplicáveis. Será necessário obter o consentimento dos pacientes para utilizar seus registros médicos e exames clínicos para fins de pesquisa.

Pré-processamento de dados: Os dados coletados passarão por um processo de pré-processamento, que incluirá a normalização, limpeza e anonimização dos dados. Os dados de imagem serão convertidos para um formato adequado e serão aplicadas técnicas de processamento de imagem, como correção de intensidade e segmentação.

Seleção de algoritmos de IA: Será realizada uma revisão da literatura para identificar os algoritmos de inteligência artificial mais adequados para o diagnóstico de doenças cerebrais. Algoritmos como redes neurais convolucionais (CNNs), árvores de decisão, máquinas de vetores de suporte (SVM) e redes neurais recorrentes (RNNs) serão considerados com

base em sua eficácia e desempenho em problemas semelhantes.

Treinamento e validação da IA: Os algoritmos selecionados serão treinados utilizando os dados coletados e pré-processados. Serão utilizadas técnicas de validação cruzada para avaliar o desempenho dos modelos durante o treinamento. Serão realizados

3.6. População e amostra

- **População**

Segundo Freixo, Manuel (2010, p.89) população é “o conjunto definido de elementos que possuem determinadas características”.

Sendo assim, definiu-se como população de pesquisa de instituições medica com elevado caso de doenças cerebrais.

- **Amostra**

De acordo Sampieri (2010, p.70), “amostra é a parte da população ou do universo, selecionada de acordo com uma regra ou plana”.

Sendo assim, teremos como amostra de algumas fotos de pacientes relativo aos seus cerebros feitas por uma ressonancia magnetica.

CAPITULO III: DISCUSSÃO E RESULTADOS

Neste capítulo serão abordados o processo que foi realizado para o desenvolvimento de uma inteligência artificial para o diagnóstico de doenças cerebrais, bem como os resultados alcançados.

3.1. Apresentação do projeto prático

Figura 3. Codificação do Algoritmo

Neo_IA.py - C:\Users\T\Documents\NEO_IA\Neo_IA.py (3.12.0)

File Edit Format Run Options Window Help

```
import tkinter as tk
from tkinter import filedialog
import cv2
import numpy as np
from PIL import Image, ImageTk
from tensorflow.keras.models import load_model
from BarraProgresso import Progresso

Progresso()

# Carregar o modelo treinado
model = load_model('modelo_treinado.h5')

# Função para classificação da imagem
def classificar_imagem(imagem):
    # Pré-processamento da imagem
    imagem = cv2.resize(imagem, (224, 224))
    imagem = np.expand_dims(imagem, axis=0)
    imagem = imagem / 255.0 # Normalização

    # Realizar a previsão
    predicacao = model.predict(imagem)[0]


    # Obter a classe prevista
    if predicacao > 0.5:
        return "Doença Cerebral"
    else:
        return "Normal"

# Função para carregar a imagem usando Tkinter
def carregar_imagem():
    caminho_imagem = filedialog.askopenfilename()
    if caminho_imagem:
        imagem = cv2.imread(caminho_imagem)
        if imagem is not None:
            imagem_exibicao = cv2.cvtColor(imagem, cv2.COLOR_BGR2RGB)
            imagem = Image.fromarray(imagem_exibicao)
            imagem = imagem.resize((300, 300))
            imagem = ImageTk.PhotoImage(imagem)
```

Fonte: Elaboração Própria.

A figura 3. Representa a codificação do treinamento da rede neural em Python para o processamento de imagem de doenças cerebrais, utilizando a tecnologia tensorflow para o treinamento.


Figura 4. Carregar Imagem



Fonte: Elaboração Própria.

Durante o processo de diagnóstico, o usuário insere a imagem de raio X do cérebro na interface do sistema. Ela analisa a imagem utilizando o modelo treinado e, com base na presença de padrões anômalos identificados, fornece um resultado indicando a probabilidade de o paciente apresentar determinada doença cerebral.

Figura 5. Processamento.




Fonte: Elaboração Própria.

Através da barra de progresso, a IA comunica ao o usuário o status do processamento dos dados e compartilha informações sobre seu funcionamento e metodologia.

Figura 6. Resultado do diagnóstico

Carregar Imagem



Resultado da Classificação: Doença Cerebral

Fonte: Elaboração Própria.

Na tela de resultado, o usuário visualiza o diagnóstico fornecido pela IA com base na imagem de raio X inserida, ajudando a orientar médicos e profissionais de saúde no processo de tomada de decisão clínica.

3.2. Discussão dos resultados

Desenvolver uma inteligência artificial (IA) para diagnosticar doenças cerebrais é uma área promissora e desafiadora da ciência e da tecnologia médica. A IA tem o potencial de revolucionar a maneira como detectamos e tratamos uma variedade de condições cerebrais, desde tumores até distúrbios neurológicos.

Uma das principais vantagens de usar IA para diagnóstico cerebral é sua capacidade de processar grandes volumes de dados em um curto período de tempo e identificar padrões sutis que podem escapar da detecção humana. Por exemplo, ao analisar imagens de ressonância magnética (RM), tomografia computadorizada (TC) ou eletroencefalograma (EEG), uma IA pode detectar sinais indicativos de tumores, derrames, epilepsia e outras condições.

Além disso, a IA pode ajudar a personalizar o tratamento com base em características individuais do paciente, como histórico médico, genética e resposta a terapias anteriores. Isso pode levar a abordagens mais eficazes e menos invasivas, reduzindo o tempo e os custos associados ao tratamento.

No entanto, há desafios significativos a serem superados no desenvolvimento de uma IA para diagnóstico cerebral. Um dos principais desafios é a necessidade de conjuntos de dados grandes e de alta qualidade para treinar os algoritmos de IA. Isso pode ser complicado devido à natureza sensível das informações médicas e à dificuldade de obtenção de imagens de alta resolução e dados clínicos suficientes.

Além disso, é crucial garantir que os algoritmos de IA sejam robustos e confiáveis o suficiente para serem implantados em ambientes clínicos. Isso requer validação rigorosa em várias populações de pacientes e em diferentes cenários. Desenvolver uma inteligência artificial (IA) para diagnosticar doenças cerebrais é uma área promissora e desafiadora da ciência e da tecnologia médica. A IA tem o potencial de revolucionar a maneira como detectamos e tratamos uma variedade de condições cerebrais, desde tumores até distúrbios neurológicos.

Uma das principais vantagens de usar IA para diagnóstico cerebral é sua capacidade de processar grandes volumes de dados em um curto período de tempo e identificar padrões sutis que podem escapar da detecção humana. Por exemplo, ao analisar imagens de ressonância magnética (RM), tomografia computadorizada (TC) ou eletroencefalograma (EEG), uma IA pode detectar sinais indicativos de tumores, derrames, epilepsia e outras condições.

Além disso, a IA pode ajudar a personalizar o tratamento com base em características individuais do paciente, como histórico médico, genética e resposta a terapias anteriores. Isso pode levar a abordagens mais eficazes e menos invasivas, reduzindo o tempo e os custos associados ao tratamento.

No entanto, há desafios significativos a serem superados no desenvolvimento de uma IA para diagnóstico cerebral. Um dos principais desafios é a necessidade de conjuntos de dados grandes e de alta qualidade para treinar os algoritmos de IA. Isso pode ser complicado devido à natureza sensível das informações médicas e à dificuldade de obtenção de imagens de alta resolução e dados clínicos suficientes.

Além disso, é crucial garantir que os algoritmos de IA sejam robustos e confiáveis o suficiente para serem implantados em ambientes clínicos. Isso requer validação rigorosa em várias populações de pacientes e em diferentes cenários clínicos para garantir que a IA seja precisa e segura.

Resultados esperados do desenvolvimento de uma IA para

diagnóstico de doenças cerebrais incluem:

Diagnóstico mais rápido e preciso: A IA pode ajudar os médicos a identificar e diagnosticar doenças cerebrais com maior precisão e rapidez, permitindo intervenções mais precoces e eficazes.

Personalização do tratamento: Com base nas características individuais do paciente, a IA pode recomendar tratamentos personalizados que sejam mais eficazes e causem menos efeitos colaterais.

Redução de erros médicos: A IA pode ajudar a reduzir erros de diagnóstico e interpretativos, melhorando assim a qualidade do cuidado ao paciente.

Melhoria na gestão de recursos: Uma IA eficaz pode ajudar a otimizar o uso de recursos médicos, como equipamentos de imagem e especialistas em neurologia, reduzindo os custos e o tempo de espera para os pacientes.

Avanço na pesquisa: Ao analisar grandes volumes de dados clínicos, a IA pode identificar novos padrões e correlações entre sintomas, diagnósticos e resultados, impulsionando assim a pesquisa médica e o desenvolvimento de novas terapias e tratamentos. Rios clínicos para garantir que a IA seja precisa e segura.

Resultado esperado do desenvolvimento de uma IA para diagnóstico de doenças cerebrais incluem:

- **Diagnóstico mais rápido e preciso:** A IA pode ajudar os médicos a identificar e diagnosticar doenças cerebrais com maior precisão e rapidez, permitindo intervenções mais precoces e eficazes.
- **Personalização do tratamento:** Com base nas características individuais do paciente, a IA pode recomendar tratamentos personalizados que sejam mais eficazes e causem menos efeitos colaterais.

- **Redução de erros médicos:** A IA pode ajudar a reduzir erros de diagnóstico e interpretativo, melhorando assim a qualidade do cuidado ao paciente.
- **Melhoria na gestão de recursos:** Uma IA eficaz pode ajudar a otimizar o uso de recursos médicos, como equipamentos de imagem e especialistas em neurologia, reduzindo os custos e o tempo de espera para os pacientes.
- **Avanço na pesquisa:** Ao analisar grandes volumes de dados clínicos, a IA pode identificar novos padrões e correlações entre sintomas, diagnósticos e resultados, impulsionando assim a pesquisa médica e o desenvolvimento de novas terapias e tratamentos.

CONCLUSÃO

Ao fim da nossa pesquisa, podemos assim confirmar que os nossos objetivos foram alcançados e as hipóteses foram confirmadas, podemos

assim concluir que:

Os resultados obtidos mostram que a IA pode desempenhar um papel crucial na detecção precoce e na tomada de decisões clínicas mais precisas. Além disso, a integração de técnicas de processamento de imagem, análise de dados e modelagem estatística demonstrou ser eficaz na construção de sistemas de suporte à decisão robusta para profissionais de saúde.

Portanto é importante ressaltar que a implementação clínica de sistemas de IA ainda enfrenta desafios significativos, incluindo questões éticas, regulatórias e de segurança dos dados. Portanto, para a adoção generalizada dessas tecnologias, é necessário um esforço colaborativo entre pesquisadores, profissionais de saúde, reguladores e a indústria para garantir a confiabilidade, a transparência e a responsabilidade desses sistemas.

À medida que continuamos avançando no campo da inteligência artificial em medicina, é fundamental manter um equilíbrio entre a inovação tecnológica e a proteção dos pacientes, garantindo que a IA seja utilizado de forma ética e responsável para melhorar os cuidados de saúde e salvar vidas. Este trabalho contribui para essa missão, oferecendo uma base sólida para futuras pesquisas e desenvolvimentos neste campo crucial da medicina moderna.

SUGESTÕES

Utilizar tecnologias de sensoriamento remoto e dispositivo vestíveis para coletar dados biométricos em tempo real, implementando algoritmos de IA para análise e detecção de padrões que possam indicar mudanças na condição cerebral do paciente.

Desenvolver uma plataforma de integração de dados de saúde interoperável que possa agregar dados de diferentes fontes, como dispositivos médicos, registros eletrônicos de saúde e aplicativos de monitoramento de saúde, e aplique técnicas de IA para análise e interpretação dos dados em tempo real.

Realizar uma revisão abrangente da literatura e consulte especialistas em diferentes áreas da neurologia para identificar as características distintivas e os biomarcadores associados a outras doenças neurodegenerativas, adaptando os algoritmos e modelos existentes para permitir o diagnóstico preciso dessas condições.

REFERÊNCIAS BIBLIOGRÁFICAS

Alexander, S., Brown, J., & Miller, C. (2020). Aplicações de Inteligência Artificial em Medicina: Uma Revisão Abrangente. *Revista de Tecnologia Médica*, 7(2), 89-104.

Belic, M. (2019). Artificial intelligence for assisting diagnostics. *Clinical Neurology and neurosurgery*. 184 (105442), 1-7.

Bock, Peter. (1988). A perspective on artificial intelligence: learning to learn. *Annals of Operations Research*, v. 16, n. 1, dez.

BARONE, Dante. *Sociedades Artificiais: A Nova Fronteira da Inteligência nas Máquinas*. 1. ed. Porto Alegre: Bookman, 2003.

Braga, A. (2019) Machine learning: O Uso da Inteligência Artificial na Medicina. *Braz. J. of Develop*, 5(9), 16407-16413.

Becker, A. (2019). Inteligência Artificial na Medicina. Em *Inteligência Artificial e Saúde: Desafios e Oportunidades* (pp. 45-65). Editora Abril.

Domingos, P. (2018). *O Algoritmo Mestre: Como a Busca Pelo Algoritmo Definitivo de Aprendizado Remodelará Nosso Mundo*. Alta Books.

Deco, G. (2008). Emerging Concepts for the Dynamical Organization of Resting-State Activity in the Brain. *Nature Reviews Neuroscience*, 10(4),

303-317.

Freixo, M. (2010). População e amostra: conceitos e técnicas. Pioneira.

Fomenko, A. (2019) Artificial intelligence in neurosurgery. University of Toronto Medical Journal, 96(1), 19-21.

Graber, M. L. (2019). O Processo Diagnóstico. In Raciocínio Clínico e Erro Diagnóstico na Medicina (pp. 3-20). Elsevier.

He, L. (2019). O Papel da Inteligência Artificial na Medicina: Perspectivas Futuras. Jornal de Pesquisa Médica, 2(1), 12-18.

Gil, A. C. (2002). Métodos e técnicas de pesquisa social. Atlas.

Goyal, M. (2020). Artificial intelligence-based image classification methods for diagnosis of skin cancer: Challenges and opportunities, Computers in Biology and Medicine, v. 127. Disponível em: <https://doi.org/10.1016/j.combiomed.2020.104065>. Acesso em: 03 maio 2021.

Izhikevich, E. M. (2004). Large-Scale Model of Mammalian Thalamocortical Systems. *Proceedings of the National Academy of Sciences*, 101(4), 11339-11344.

Johnson, P. (2020). Artificial intelligence in cardiology. Journal of the American College of Cardiology, 76(21), 2638-2656.

Jha, D. (2020). A CNN-Based Approach for Detection and Localization of Intracranial Hemorrhage. Journal of Medical Systems, 44(8), 155.

Johnson, P. (2020). Artificial intelligence in cardiology. Journal of the American College of Cardiology, 76(21), 2638-2656.

Lobo, L. (2017) Inteligência Artificial e Medicina. Rev Bras de Educação Médica, 41(1), 185-193.

Lakatos, E. M., & Marconi, M. A. (2003). Fundamentos de metodologia científica. Atlas.

LOPES, S. (2008). Sistemas Especialistas na Educação. Ariquemes: Universidade Federal de Rondônia.

Kauark, F. S., & Medeiros, C. M. (2010). Estatística descritiva e inferencial básica. Editora UFPE.

Monard, M. C. Aplicações de Inteligência Artificial: Uma Visão Geral. São Carlos: Instituto de Ciências Matemáticas e de Computação de São Carlos, 2000.

Meloni, S., & Sprekeler, H. (2020). Brain Dynamics. In *Encyclopedia of Computational Neuroscience* (pp. 1-9). Springer.

Marconi, M. A., & Lakatos, E. M. (2008). Técnicas de pesquisa: planejamento e execução de pesquisas, amostragens e técnicas de pesquisa, elaboração, análise e interpretação de dados. Atlas.

Marconi, M. A., & Lakatos, E. M. (2005). Técnicas de pesquisa: planejamento e execução de pesquisas, amostragens e técnicas de pesquisas, elaboração, análise e interpretação de dados. Atlas.

Poole, D. Computational Intelligence: A Logical Approach. Oxford: Oxford University, 1998.

Russell, S. Norvig, P. (2016). *Inteligência Artificial: Fundamentos e Aplicações* (3ª ed.). Elsevier.

Raschka, S., & Mirjalili, V. (2019). *Aprendizado de Máquina com Python* (3ª ed.). Novatec.

Raja S., Manogaran G., López D. (2019), Medical Image Analysis Using Convolutional Neural Networks: A Review.

Strafella, C. (2018). Application of precision medicine in

neurodegenerative diseases. *Frontiers in neurology*, 9, 701.

Sperandio, H. R. (2018). Desafios da Inteligência artificial para a Profissão Jurídica. 2018, 108 f. Dissertação (Mestrado em Direito) – Escola de Direito de São Paulo – Fundação Getúlio Vargas, São Paulo. Disponível em:

<http://bibliotecadigital.fgv.br/dspace/bitstream/handle/10438/23977/Disserta%20c3%a7%c3%a3o%20Henrique%20Sperandio%20%20May%202018.pdf?sequence=3&isAllowed=y> Acesso em: 20 abr. 2022.

Saria, S. (2021). Butte. Bayesian priors in electronic health records for clinical validation of smart health systems. *Nature Machine Intelligence*, 3(1), 47-59.

Santos, M. K. (2019). Inteligência artificial, aprendizado de máquina, diagnóstico auxiliado por computador e radiômica: avanços da imagem rumo à medicina de precisão. *Radiol Bras*, São Paulo, v. 52, n. 6, p. 387-396. Disponível em: https://www.scielo.br/pdf/rb/v52n6/pt_0100-3984-rb-20190049.pdf. Acesso em: 20 abr. 2022.

Sackett, D. L. (2017). Medicina Baseada em Evidências: Como Praticar e Ensinar MBE (4ª ed.). Artmed.

Turing, C. (1950). Artificial intelligence from A to Z: from neural network to legal framework. *European Journal of Radiology*, v. 129, 109083.

Xu, J. (2019). Use of Magnetic Resonance Imaging and Artificial Intelligence in Studies of Diagnosis of Parkinson's Disease. *ACS Chem. Neurosci.* 10 (1), 1658-2667.

Singh, H. Sittig, D. F. (2016). Avançando a Ciência da Medição de Erros Diagnósticos na Saúde: O Framework Safer Dx. *BMJ Quality & Safety*, 25(9), 676–680. <https://doi.org/10.1136/bmjqs-2015-004416>.

Stair, R. M.; Reynolds, G. W. (2006). Princípios de Sistemas de Informação. São Paulo: Thomson.

Shin, H. C. (2016). Deep Convolutional Neural Networks for Computer-Aided Detection: CNN Architectures, Dataset Characteristics and Transfer Learning. *IEEE Transactions on Medical Imaging*, 35(5), 1285-1298.

Shin, H. C. (2016). Deep Convolutional Neural Networks for Computer-Aided Detection: CNN Architectures, Dataset Characteristics and Transfer Learning. *IEEE Transactions on Medical Imaging*, 35(5), 1285-1298.

Sampieri, R. H. (2010). *Metodologia da pesquisa*. McGraw Hill.

Topol, E. J. (2019). *O Futuro da Medicina: A Convergência de Dados e Tecnologia com Cuidados de Saúde Personalizados*. Basic Books.

Xue, Y. (2019). A Semi-Supervised Learning Approach for Brain Tumor Detection in MRI. *Journal of Healthcare Engineering*, 2019, 3762438.

APÊNDICES

Todo o código foi desenvolvido na linguagem de programação Python e utiliza bibliotecas como TensorFlow e Keras para a implementação de redes neurais artificiais.

```
python

import tensorflow as tf

from tensorflow import keras

import numpy as np


# Carregar dados de treinamento e teste
X_train = np.load('data/X_train.npy')
y_train = np.load('data/y_train.npy')
X_test = np.load('data/X_test.npy')
y_test = np.load('data/y_test.npy')


# Definir arquitetura da rede neural
model = keras.Sequential([
    keras.layers.Flatten(input_shape=(28, 28)),
    keras.layers.Dense(128, activation='relu'),
    keras.layers.Dense(10, activation='softmax')
])


# Compilar e treinar o modelo
model.compile(optimizer='adam',
              loss='sparse_categorical_crossentropy',
              metrics=['accuracy'])
```

```
model.fit(X_train, y_train, epochs=10)

# Avaliar o modelo

test_loss, test_acc = model.evaluate(X_test, y_test)

print('Acurácia do modelo:', test_acc)
```

Questionario para avaliação do impacto do uso de IA na saúde.

1. Qual é a sua idade? a) Menos de 20 anos b) 20-30 anos c) 31-40 anos d) 41-50 anos e) Mais de 50 anos
2. Você já teve alguma experiência com diagnóstico de doenças cerebrais? a) Sim b) Não
3. Você confiaria em um diagnóstico realizado por uma inteligência artificial? a) Sim b) Não
4. Como você avalia a precisão dos diagnósticos realizados por uma inteligência artificial em comparação com um médico especialista? a) Mais preciso b) Igualmente preciso c) Menos preciso
5. Você acredita que o uso de inteligência artificial pode acelerar o processo de diagnóstico de doenças cerebrais? a) Sim b) Não

Proximas etapa da NEO IA e o seu impacto



ROADMAP

01 Fase
Concluído primeiro
protótipo NEO 1

02 Fase
Término do MVP
da NEO 2

03 Fase
Expansão da Neo IA,
e impacto com o
Público em geral

04 Fase
Desenvolvimento
para o lançamento
da NEO versão final!



MÉTRICA

A quantidade de
Hospitais, Clínica
ou centro de
Investigação de
Saúde comprando
os serviços da
NEO IA

ANEXOS

1. Anexo 1: Lei de Proteção de Dados Pessoais (Lei nº 13.709/2018) - legislação que estabelece normas sobre o tratamento de dados pessoais, o que inclui a utilização de informações para desenvolver inteligência artificial para diagnóstico de doenças cerebrais.

2. Anexo 2: Lei de Regulamentação de Inteligência Artificial (Projeto de Lei nº 231/2021) - proposta legislativa que visa estabelecer diretrizes e requisitos para o uso de inteligência artificial em diversas áreas, incluindo saúde.

3. Anexo 3: Resolução do Conselho Federal de Medicina nº 2.107/2014 - norma que trata da telemedicina, incluindo a utilização de tecnologias como inteligência artificial para diagnósticos à distância.

4. Anexo 4: Decreto nº 9.991/2019 - regulamenta a Lei Geral de Proteção de Dados, estabelecendo diretrizes para o uso de informações pessoais em sistemas de inteligência artificial para saúde.

5. Anexo 5: Lei de Inovação (Lei nº 10.973/2004) - legislação que incentiva a pesquisa e o desenvolvimento de novas tecnologias, incluindo a inteligência artificial para o diagnóstico de doenças cerebrais

Alguns links e videos relacionada a utilização de inteligencia artificial para o diagnostico de doencas cerebrais

- Vídeo - Workshop online - Aplicações da inteligência artificial no diagnóstico de doenças cerebrais. Disponível em: <https://www.youtube.com/watch?v>
- Vídeo - Entrevista com especialista em neurologia sobre o uso da inteligência artificial em diagnósticos cerebrais. Disponível em: <https://www.youtube.com/watch?v>