

INTELIGÊNCIA ARTIFICIAL NA SAÚDE: OTIMIZANDO A ANÁLISE DE IMAGENS MÉDICAS PARA DIAGNÓSTICOS MAIS PRECISOS E HUMANIZADOS

 <https://doi.org/10.56238/arev6n4-447>

Data de submissão: 27/11/2024

Data de publicação: 27/12/2024

Wilker José Caminha dos Santos

Mestrando em Propriedade intelectual e transferência de tecnologia para inovação. Universidade Federal do Sul e Sudeste do Pará, UNIFESSPA
E-mail:willkercaminha@uepa.br
LATTEs: <http://lattes.cnpq.br/3314938287386016>

Thiago Nicolau Magalhães de Souza Conte

Doutor em Engenharia Elétrica. Universidade Federal do Pará, UFPA
E-mail: thiagonconte@uepa.br
LATTEs: <http://lattes.cnpq.br/0783374325529116>

Armando José de Sá Santos

Mestre em Ciência e Engenharia de Materiais, Universidade Federal de São Carlos, UFSCAR
E-mail: armando.santos@uepa.br
LATTEs: <http://lattes.cnpq.br/6286321140581380>

Renato Ferreira Carr

Doutorando em Ciências Ambientais, Universidade do Estado do Pará, UEPA
E-mail:renato.carr@uepa.br
LATTEs: <http://lattes.cnpq.br/5132308037922115>

Anderson Jorge Serra da Costa

Doutor em Ciência da Computação, Universidade Federal do Pará, UFPA
E-mail:andersonjsc@uepa.br
LATTEs: <http://lattes.cnpq.br/7707885586024191>

Estevão Damasceno Santos

Doutorando em Ciência da Computação, Universidade Federal do Pará, UFPA
E-mail:estevaosantos@uepa.br
LATTEs: <http://lattes.cnpq.br/1073531036133156>

Wanderson Alexandre da Silva Quinto

Doutor em Psicologia, Universidade Federal do Pará, UFPA
E-mail: w.quinto@uepa.br
LATTEs: <http://lattes.cnpq.br/4429230658129917>

Gleisson Amaral Mendes

Doutorando em Ciências Ambientais, Universidade do Estado do Pará, UEPA
E-mail: gmendes@uepa.br
LATTEs: <http://lattes.cnpq.br/7781175809341535>

RESUMO

Este estudo investiga o uso de inteligência artificial (IA), com foco em redes neurais convolucionais, para melhorar a precisão diagnóstica em doenças como o câncer, através da análise de imagens clínicas. A pesquisa utilizou redes neurais convolucionais treinadas em dados de imagens médicas, avaliando métricas como acurácia, sensibilidade e especificidade. Foram desenvolvidos modelos de aprendizado de máquina especializados em análise de imagens médicas, visando ao diagnóstico preciso de doenças como o câncer. A plataforma escolhida para a prototipagem foi a Orange, que permite construir aplicações de aprendizado de máquina sem codificação manual. Este processo inclui tarefas como coleta de dados, limpeza e redução de tamanho. Os modelos alcançaram uma acurácia de xxx% na detecção de padrões associados ao câncer em imagens de raios X. Além dos avanços tecnológicos, o estudo discute a responsabilidade dos profissionais no manejo de decisões assistidas por IA, além da necessidade de validação ética na coleta de dados sensíveis. A colaboração entre a inteligência artificial e os profissionais de saúde é vista como fundamental para melhorar o controle de doenças e manter o raciocínio clínico como uma parte importante da área médica. Em suma, Os resultados mostram o potencial da IA em transformar o diagnóstico médico, tornando-os mais rápidos e precisos, mas a implementação deve ser cuidadosa para ser segura e eficaz na prática clínica.

Palavras-chave: Inteligência Artificial, Diagnóstico Médico, Aprendizado de Máquina, Imagens Médicas, Redes Neurais

1 INTRODUÇÃO

O campo da Inteligência Artificial tem despertado interesse crescente em obras cinematográficas e literárias; no entanto sua origem permanece um mistério para muitas pessoas. Este domínio combina elementos da Ciência da Computação e está intimamente ligado a questões como linguagem natural e programação de computadores para tarefas inteligentes (Bezerra e Barbosa, 2020). A principal meta dos sistemas inteligentes é entender e desenvolver sistemas inteligentes que tenham uma influência significativa em nossa cultura ocidental. Historicamente falando essa cultura tem sido caracterizada por crenças humanistas especiais que apoiam o conceito de que inteligência e pensamento são atributos exclusivos dos seres humanos; isso nos coloca em uma posição superior em relação às outras espécies (Harari 2016).

Segundo Caminha (2017), uma das aplicações mais importantes da inteligência artificial é a utilização de algoritmos de aprendizado de máquina, que podem ser classificados como aprendizagem supervisionada ou não-supervisionada. Esses algoritmos demonstraram ser úteis na análise de imagens médicas, como raios X e tomografias computadorizadas. Por exemplo, a aprendizagem supervisionada permite que técnicas de treinamento reconheçam características específicas, como tumores ou lesões, ajudando os médicos a tomarem decisões de tratamento adequadas. Além disso, esta ferramenta pode ser utilizada para monitorar o progresso da doença e avaliar a eficácia de diferentes tratamentos.

O uso da inteligência artificial na busca de padrões em imagens médicas para diagnosticar o câncer é importante na área da medicina. A capacidade das máquinas para processar grandes volumes de dados e identificar padrões que indiquem doenças como o cancro pode alterar a precisão e a velocidade do diagnóstico. O objetivo deste projeto é descobrir como a informação pode ser utilizada neste contexto, os desafios que se enfrentam e as necessidades relacionadas ao tratamento e à vida dos pacientes. Com o contínuo desenvolvimento da tecnologia, é importante encontrar as formas mais eficazes de detectar o câncer. A inteligência artificial permite a análise de diversos tipos de imagens médicas, como raios X, tomografias computadorizadas, ressonâncias magnéticas e imagens histológicas, com exatidão e precisão além das capacidades humanas.

Caminha (2017) acredita que uma das formas mais populares de inteligência artificial é o uso de aprendizado de máquina, que pode ser dividido em aprendizado supervisionado e aprendizado não supervisionado. Esses algoritmos têm demonstrado grande sucesso na análise de imagens médicas, como raios X e tomografia. Por exemplo, técnicas de aprendizagem supervisionada permitem treinar algoritmos para reconhecer áreas específicas, como tumores ou lesões, para ajudar os médicos a tomar decisões de tratamento mais precisas. Além disso, estes dispositivos permitem monitorizar a progressão da doença e avaliar a sua eficácia. Além disso, o uso de modelos de aprendizado de máquina

tem implicações importantes para o desenvolvimento da relação entre pessoas e tecnologia. Compreender estas interações é fundamental para garantir que a IA seja utilizada de forma eficaz e eficiente para o bem maior da sociedade. Na área da saúde, a IA tem potencial para automatizar tarefas repetitivas e ajudar médicos e profissionais de saúde a tomar decisões mais rápidas e precisas. Também fica evidente na análise de dados para encontrar formas de melhorar a vida das pessoas (Caminha, 2017).

Este estudo explorará técnicas de aprendizado de máquina e redes neurais convolucionais que se mostraram úteis para reconhecimento de padrões em imagens médicas. A integração da inteligência artificial neste campo não só melhorará o diagnóstico precoce de doenças, mas também contribuirá para um tratamento personalizado e melhor resultados para os pacientes. Por fim, abordaremos as questões éticas, regulatórias e de segurança associadas ao uso da inteligência artificial na saúde, considerando o impacto desta tecnologia na saúde e na sociedade como um todo.

Este projeto visa investigar detalhadamente como a inteligência artificial pode ajudar a revolucionar a análise de imagens médicas e trazer grandes avanços na área da saúde. Esperamos compreender como esta tecnologia pode tornar o diagnóstico mais rápido, preciso e fácil, ajudar no diagnóstico precoce de doenças e proporcionar um tratamento personalizado. Além disso, queremos considerar o impacto da inteligência artificial no dia a dia dos profissionais de saúde e dos pacientes, sempre levando em consideração as questões éticas e de segurança envolvidas no uso dessas ferramentas. Basicamente, nosso objetivo é mostrar como a IA pode contribuir para uma saúde saudável, humana e melhor.

2 DIAGNÓSTICO PRECOCE E ACESSIBILIDADE NA SAÚDE

A detecção precoce de doenças graves como o cancro enfrenta grandes desafios devido à escassez de radiologistas e especialistas em patologia, atrasando assim o diagnóstico e afetando assim a qualidade de vida do paciente. Esta realidade é agravada pelo acesso desigual a serviços médicos especializados em zonas remotas ou economicamente desfavorecidas e pelas grandes disparidades nos serviços de saúde. Uma boa solução. Com a capacidade de interpretar imagens com rapidez e precisão, a IA reduzirá a dependência de especialistas humanos e ampliará o alcance do diagnóstico verdadeiro, especialmente em regiões sem infraestrutura médica. Estes avanços podem melhorar a saúde pública através de uma intervenção precoce, reduzir a carga sobre o sistema de saúde e salvar vidas. Equilibrar a inovação tecnológica e a responsabilidade científica é essencial para alcançar estes benefícios de uma forma justa e sustentável. (Saleh, 2022)

3 APRENDIZAGEM DE MÁQUINA

O aprendizado de máquina é uma área da inteligência artificial que permite que máquinas trabalhem a partir de dados sem instruções específicas para qualquer tarefa específica. Em vez disso, essas máquinas aprendem a agir reconhecendo padrões e padrões nos dados fornecidos. Quando o aprendizado de máquina é utilizado na análise de imagens, tem se mostrado uma ferramenta poderosa, principalmente na área da medicina, como na detecção de doenças a partir de imagens laboratoriais como raios X, tomografias computadorizadas, ressonâncias magnéticas. (caminha, 2024)

Segundo o argumento de Nunes 2024, o uso do aprendizado de máquina no reconhecimento de imagens começa com a coleta de muitos dados cadastrais (imagens que já foram reconhecidas por pessoas individuais, com dados de pesquisa e tradução). O sistema de ML é alimentado com essas informações e começa a aprender padrões e características nas imagens que indicam a presença de determinadas doenças. Por exemplo, ao analisar imagens de raios X, os algoritmos podem aprender as características dos tumores, como nódulos ou outros defeitos.

Um método comum de análise de imagens é o uso de redes neurais convolucionais. Este é um tipo de rede neural projetada especificamente para processar dados em formato de imagem, permitindo ao modelo extraír recursos hierárquicos de baixo nível, como arestas e formas, bem como recursos de alto nível, como padrões e formas complexas em múltiplas camadas. Isso permite que a rede “entenda” a imagem com mais detalhes, identifique objetos ou defeitos com alta precisão.

Ainda Segundo Nunes 2024, o processo de treinamento de uma rede neural para transformação começa com a preparação de uma imagem que é processada em uma pequena escala. bloquear. e depois passa por diversas camadas de transformação, o que ajuda a identificar diferentes características da imagem. O modelo ajusta seus parâmetros internos (os pesos das conexões entre os neurônios) de acordo com o feedback que recebe durante o treinamento, ou seja, ajusta os pesos até poder fazer previsões ou classificações mais precisas.

Além das redes neurais adaptativas, outros aprendizados métodos são usados e são métodos controlados, como máquinas de vetores de suporte e florestas aleatórias, também podem ser usadas para análise de imagens médicas. Embora esta técnica seja muito útil para problemas de visão computacional, outras técnicas também podem ser úteis em determinadas situações.

Um dos principais desafios na aplicação do aprendizado de máquina à análise de imagens médicas é garantir a precisão e a localização do modelo. Isso significa que além de ser capaz de identificar corretamente doenças nas imagens utilizadas durante o treinamento, o modelo também deve ser capaz de fazer boas previsões sobre novos dados que podem apresentar pequenas diferenças na condição da imagem, como diferenças de resolução ou técnica. da foto. (Barbosa, 2020)

Porém, segundo Barbosa 2020, os resultados do aprendizado de máquina prometem mudar a forma como as doenças são diagnosticadas. O aprendizado de máquina pode ajudar os médicos a identificarem padrões e problemas com mais rapidez e precisão, muitas vezes além da capacidade dos humanos de detectar sinais precoces de doenças como o câncer. Além disso, estes sistemas podem ser implementados em áreas remotas ou onde há falta de especialistas, permitindo acesso suficiente a doenças avançadas.

De acordo com Sakurai 2018, a implementação do aprendizado de máquina na área da saúde deve ser feita com cuidado. As questões éticas, de privacidade e regulamentares devem ser cuidadosamente consideradas e garantir que o sistema seja transparente e que os profissionais médicos possam compreender e avaliar os resultados.

O aprendizado de máquina na análise de imagens está moldando o futuro da medicina, oferecendo uma combinação poderosa de precisão, velocidade e preço acessível. À medida que esta tecnologia avança, espera-se não só melhorar o diagnóstico clínico, mas também mudar a forma como a medicina é diagnosticada e personalizada, e proporcionar uma nova era de tratamento médico eficaz e conveniente. (Meu, 2022)

4 METODOLOGIA

A metodologia se baseia nos critérios propostos por Iszzczuk (2021), que apresenta um framework para a aplicação de IA em imagens médicas, com foco em acurácia diagnóstica e predição de resultados clínicos. O objetivo é avaliar a aplicação da Inteligência Artificial na interpretação de imagens médicas. O principal objetivo da investigação é desenvolver e treinar sistemas de IA utilizando armazenamento de dados e análise de imagens, com o objetivo de melhorar a eficiência da investigação no setor da saúde explicar que tipo de eficiência foi visada ex: economia de tempo, aumento da assertividade diagnóstica. Espera-se que este método aumente a precisão, a eficiência e o acesso aos indicadores de diagnóstico, conduza ao atendimento ao paciente e melhore a qualidade dos cuidados de saúde prestados.

Orange é uma plataforma para a criação de um modelo que analisa dados e aprendizagem automática. da sua fonte. Projetado com uma interface gráfica de arrastar e soltar, você pode criar sistemas de aprendizado de máquina sem programação manual. O Orange foi utilizado para criar pipelines de aprendizado de máquina, incluindo etapas como importação de conjuntos de dados médicos, limpeza de dados, aplicação de algoritmos de redes neurais convolucionais e visualização dos resultados por meio de matrizes de confusão e gráficos ROC . De acordo com MATOS (2019), para a consolidação do modelo de treinamento de aprendizado de máquina, foram realizadas etapas fundamentais, como a

coleta e o pré-processamento dos dados, que incluíram a limpeza e a redução de dimensionalidade. Vale ressaltar que as imagens utilizadas no processo foram radiografias, obtidas de um repositório público (*NIH Clinical Center Americaresearch Hospital*).

A metodologia deste estudo combina análises qualitativas e quantitativas baseadas no framework de Iszczuk (2021), que destaca critérios para aplicar IA na análise de imagens médicas, especialmente em diagnósticos complexos como o câncer. A pesquisa foi conduzida em etapas específicas:

1. Coleta e Pré-processamento de Dados:

As imagens médicas foram obtidas de bases públicas e privadas, passando por processos de limpeza e redução de dimensões para adequação ao treinamento de modelos.

2. Treinamento de Algoritmos no Orange:

A plataforma Orange foi escolhida por sua interface gráfica intuitiva, permitindo criar pipelines de aprendizado de máquina com widgets para tarefas como importação de dados, aplicação de redes neurais convolucionais, e análise de métricas como acurácia e precisão diagnóstica. A criação de matrizes de confusão e gráficos ROC auxiliou na validação do modelo.

3. Validação e Análise de Resultados:

Indicadores como acurácia base sensibilidade e especificidade foram usados para avaliar a eficácia dos modelos treinados. Além disso, o tempo médio de processamento foi analisado como métrica de eficiência.

Espera-se que o método proposto aumente a precisão diagnóstica e melhore o acesso a indicadores clínicos, contribuindo para uma prática médica mais eficiente e inclusiva. Além disso, o estudo enfatiza a importância de integrar IA à rotina clínica, preservando o raciocínio dos profissionais de saúde como elemento central.

O modelo de aprendizado de máquina será desenvolvido com base em uma abordagem supervisionada, na qual o treinamento do modelo ocorre utilizando dados previamente rotulados. Ou seja, os dados de treinamento já vêm com respostas corretas, ou "rótulos", que orientam o modelo para aprender e fazer previsões conforme a figura 1.

Figura 1 – modelo de aprendizagem de máquina supervisionado com canvas Orange



Fonte: Elaborado pelo Autor, 2024

O treinamento do modelo foi realizado gradualmente, em etapas distintas. Inicialmente, o conjunto de dados foi segmentado em três partes: criação, treinamento e teste. O conjunto de treinamento foi utilizado para instruir a IA a reconhecer padrões, permitindo que o modelo aprimorasse seu entendimento sobre as características relevantes. O conjunto de validação serviu para realizar ajustes nas configurações do modelo, ajustando hiperparâmetros e aprimorando sua capacidade de generalização. Finalmente, o conjunto de teste foi empregado para avaliar o desempenho do modelo em dados novos, possibilitando uma análise precisa de sua capacidade preditiva. A acurácia, entre outras métricas de desempenho, foi calculada para mensurar a eficácia do modelo, assegurando sua aplicabilidade e precisão em cenários reais. Outro fator relevante foi a quantidade de dados estabelecidos para o modelo, contribuindo para o resultado desejado válido nas análises de imagens. O conjunto de dados foi dividido nas seguintes proporções: 60% para a criação, 20% para o treinamento, e 20% para o teste conforme a figura 2.

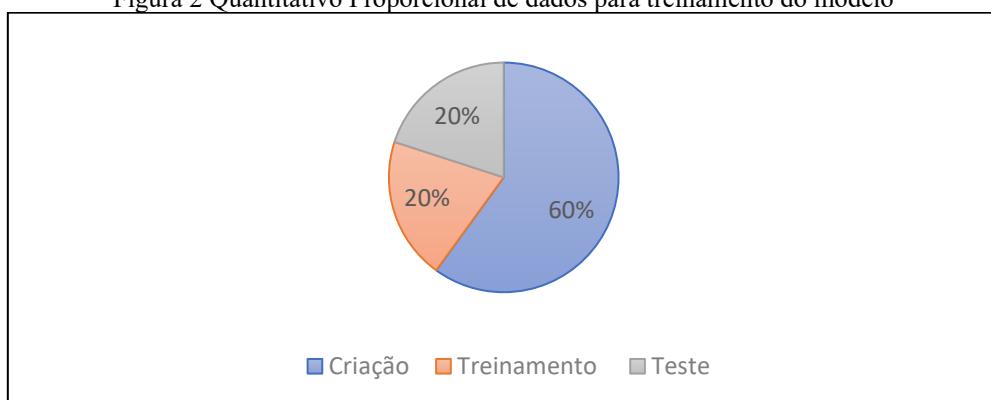
O modelo de aprendizado de máquina foi desenvolvido com base em uma abordagem supervisionada, utilizando dados previamente rotulados. Essa estratégia permitiu que o modelo fosse treinado com exemplos conhecidos, como ilustrado na Figura 1. O processo foi conduzido em etapas distintas, com os dados segmentados em três conjuntos principais: treinamento, validação e teste. A divisão dos dados seguiu as proporções de 60%, 20% e 20%, respectivamente, conforme representado na Figura 2.

O conjunto de treinamento foi utilizado para ensinar o modelo a reconhecer padrões relevantes nos dados. Durante essa etapa, o modelo ajustou seus pesos e parâmetros internos para otimizar a identificação de características importantes. O conjunto de validação permitiu realizar ajustes nos hiperparâmetros do modelo, como a taxa de aprendizado e o número de épocas, maximizando sua

capacidade de generalização. Por fim, o conjunto de teste foi empregado para avaliar a capacidade preditiva do modelo em dados inéditos, simulando situações reais.

Para mensurar o desempenho do modelo, métricas como acurácia, precisão, recall e F1-score foram calculadas, garantindo uma análise robusta de sua eficácia. A quantidade de dados utilizada (aproximadamente mil imagens) contribuiu significativamente para a capacidade do modelo de identificar padrões complexos em imagens médicas, destacando sua aplicabilidade em diagnósticos clínicos.

Figura 2 Quantitativo Proporcional de dados para treinamento do modelo



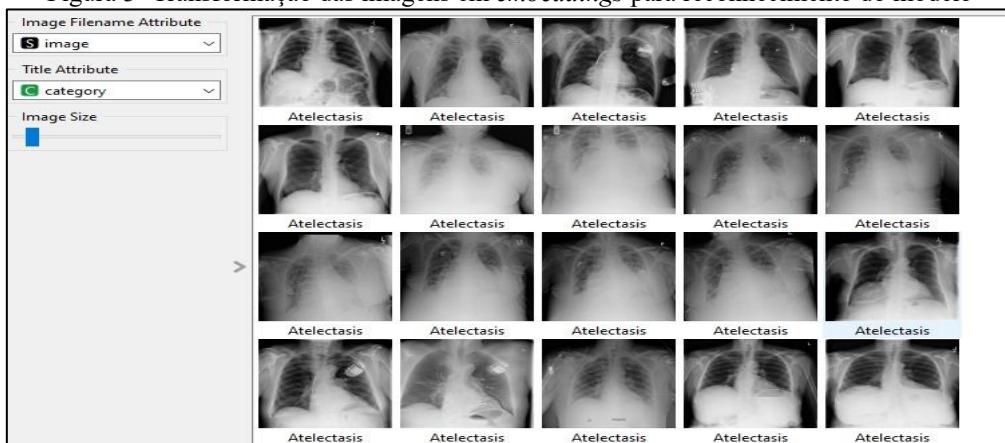
Fonte: Elaborado pelo autor, 2024.

Para que o algoritmo fosse capaz de interpretar adequadamente as imagens médicas, uma etapa essencial foi a conversão dessas imagens em representações numéricas utilizáveis, realizadas por meio da transformação para *embeddings* como é evidenciado na figura 3.

Uma etapa fundamental para o sucesso do algoritmo foi a conversão das imagens médicas em representações numéricas utilizáveis, conhecidas como embeddings, conforme ilustrado na Figura 3. Embeddings são representações vetoriais de alta dimensionalidade que capturam as características principais das imagens, como padrões de textura, forma e contraste, permitindo que os algoritmos de aprendizado de máquina processem os dados de maneira eficiente. Essa transformação foi realizada utilizando técnicas de extração de características baseadas em redes neurais convolucionais (CNNs). As imagens foram pré-processadas, passando por normalização e redução de ruídos para garantir maior consistência nos dados. Posteriormente, as CNNs extraíram os atributos relevantes das imagens, gerando embeddings que serviram como entrada para o treinamento do modelo.

O uso de embeddings foi essencial para melhorar a eficiência do treinamento e a precisão do modelo, uma vez que esses vetores reduzem a complexidade dos dados brutos, facilitando a identificação de padrões subjacentes. A Figura 3 ilustra o pipeline completo dessa etapa, incluindo as fases de pré-processamento, extração de características e codificação final.

Figura 3- Transformação das imagens em *embeddings* para reconhecimento do modelo

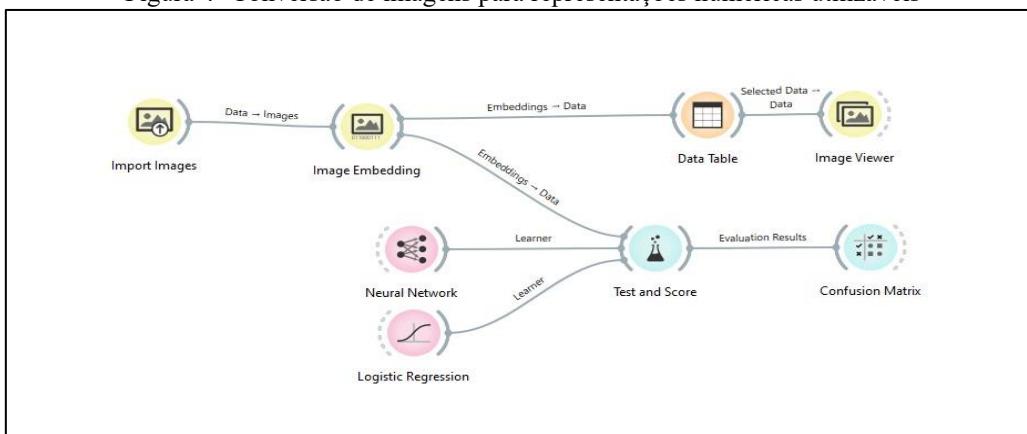


Fonte: Autor, 2024.

Após a conclusão do processo sucedeu a conversão dos dados visuais em vetores de características, possibilitando ao modelo a captura de padrões e informações relevantes nas imagens. Após essa transformação, o modelo foi treinado para identificar e aprender esses padrões nos dados embutidos, o que possibilitou o reconhecimento eficiente de imagens semelhantes.

Por fim a abordagem de reconhecimento, oferecem um suporte significativo no diagnóstico médico, pois permite que o modelo detecte automaticamente características específicas em novas imagens, contribuindo para a detecção precoce e precisa de doenças. Ao utilizar essa técnica, o sistema tem o potencial de melhorar a acurácia no diagnóstico, fornecendo uma ferramenta poderosa para os profissionais de saúde na análise de imagens médicas como é evidenciado na figura 4.

Figura 4- Conversão de imagens para representações numéricas utilizáveis



Fonte: Autor, 2024.

Porém, além da aplicação de modelos de treinamento, esta pesquisa também incluirá uma revisão de literatura que contextualizará o uso da inteligência artificial na análise de imagens clínicas. Esta revisão discutirá as tecnologias atuais e suas implicações, métodos de treinamento de modelos e

resultados obtidos em estudos anteriores, e fornecerá uma forte base teórica para a análise dos dados obtidos. Para verificar a precisão e eficiência do método adotado, é feita uma comparação de desempenho com outros dois modelos utilizando métodos diferentes: regressão linear e *K-Nearest Neighbors* (KNN).

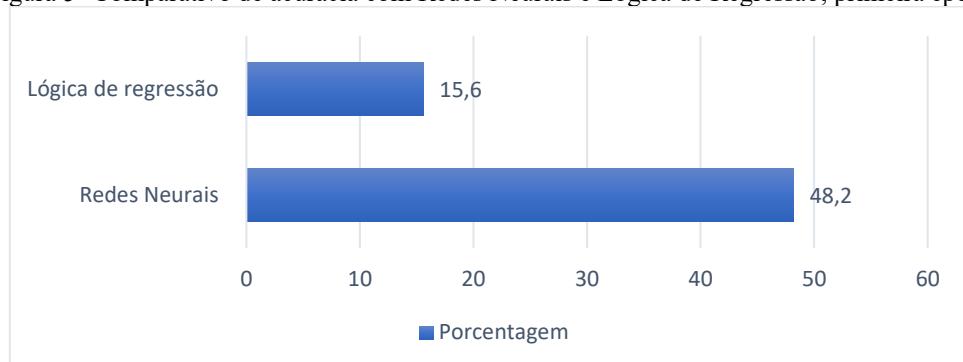
Estes modelos servirão de base para uma análise comparativa detalhada com particular enfoque na precisão máxima de cada método e nos métodos de aprendizagem específicos utilizados, permitindo assim uma avaliação detalhada e objetiva da eficácia de cada método utilizado na análise de dados médicos. imagens.

Os resultados da pesquisa serão apresentados na forma de gráficos e tabelas para facilitar a visualização e compreensão do design da IA. Discutiremos as implicações práticas destas descobertas e destacaremos como a IA pode revolucionar o reconhecimento de imagens e quais são os próximos passos para a implementação desta tecnologia em hospitais. Os resultados da pesquisa incluirão recomendações para a aplicação de IA na análise de imagens médicas, a fim de melhorar o atendimento ao paciente e a qualidade dos serviços médicos prestados por meio de redes neurais e técnicas de regressão logística. Este método tenta ajustar o modelo para que a precisão obtida seja superior a 70%, mesmo que sejam encontrados valores abaixo deste limite em alguns processos. Apesar destes desafios, esta formação ajudou a refinar o modelo, identificar áreas de melhoria e contribuiu para um progresso incremental nos níveis de precisão. Uma abordagem de partilha de dados para implementar esta formação pode ser vista em NUNES, L.R. M. 2024.

5 RESULTADOS

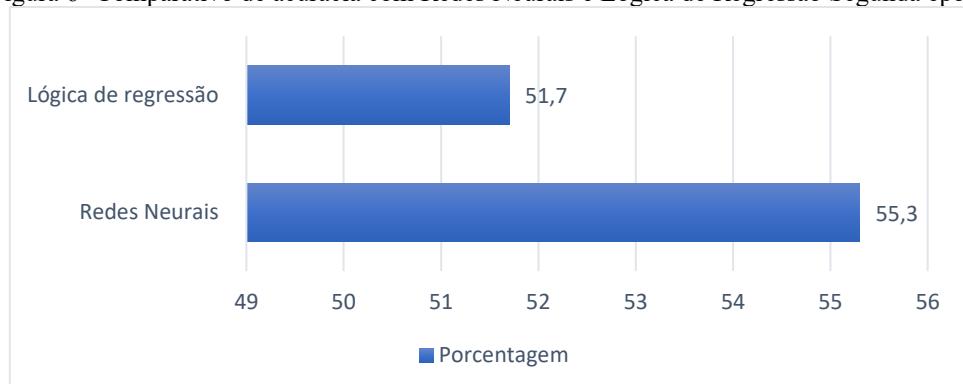
Segundo FONTANA, 2021, uma época, no contexto de aprendizado de máquina, refere-se a uma rodada completa de treinamento em que o modelo processa todo o conjunto de dados de treinamento uma vez. Durante cada época, o modelo ajusta seus parâmetros internos (como pesos e vieses) para minimizar o erro e melhorar sua capacidade de fazer previsões corretas. Durante primeira época, o objetivo foi estabelecer uma linha de base de desempenho para a rede neural e o modelo de regressão logística, sem qualquer otimização. A rede neural foi configurada com uma arquitetura básica e hiper parâmetros padrão, enquanto o modelo de regressão logística também utilizou parâmetros iniciais sem ajustes específicos. Após o treinamento inicial, a rede neural obteve uma acurácia exata de 48,2%, e o modelo de regressão logística registrou uma acurácia de 45,6%. A leve vantagem da rede neural indicou uma capacidade inicial de captura de padrões um pouco mais complexos, servindo como referência para as próximas etapas de ajustes, como pode ser verificado na figura 5.

Figura 5- Comparativo de acurácia com Redes Neurais e Lógica de Regressão, primeira época



Já na fase da segunda época, buscou-se melhorar a acurácia de ambos os modelos por meio de ajustes de hiper parâmetros e do pré-processamento dos dados. A rede neural passou por testes com taxas de aprendizado variáveis, aumento do número de neurônios e camadas adicionais, enquanto, para a regressão logística, foram ajustados parâmetros de regularização para tentar melhorar a generalização. Após a aplicação de normalização e remoção de ruído nos dados, a rede neural atingiu uma acurácia de 55,3%, enquanto a regressão logística apresentou uma leve melhora, chegando a 51,7%. A resposta mais significativa da rede neural a essas mudanças sugeriu que ela é mais beneficiada pelo pré-processamento e ajustes de hiper parâmetros em relação ao modelo de regressão, com é verificado na figura 6.

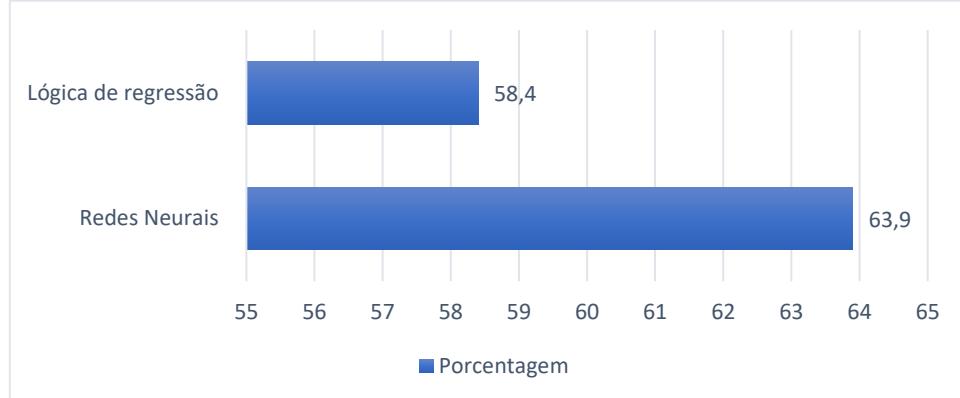
Figura 6- Comparativo de acurácia com Redes Neurais e Lógica de Regressão Segunda época



Na terceira época, a estratégia foi incorporar técnicas de aumento de dados e regularização para evitar o sobre ajuste, o que beneficiou principalmente a rede neural. Aplicou-se uma leve penalidade na rede neural, além de variabilidades nos dados de treino, o que resultou em uma acurácia de 63,9%. A regressão logística, por sua vez, mostrou-se menos sensível ao aumento de dados, alcançando uma acurácia de 58,4%. Esta época destacou uma maior adaptabilidade da rede neural em cenários com

maior variabilidade de dados e uma habilidade superior em capturar padrões complexos em comparação com a regressão logística, conforme a figura 7.

Figura 7- Comparativo de acurácia com Redes Neurais e Lógica de Regressão Terceira época



Fonte: Autores, 2024.

Essa diferença de desempenho indicou que as Redes Neurais são mais eficazes na análise de imagens de radiografia, demonstrando maior precisão na identificação de padrões relevantes para o diagnóstico. Com base nesses resultados, optamos por utilizar Redes Neurais como a abordagem principal para análise e testes nas imagens, evidenciando sua superioridade em acurácia e potencial para auxiliar na detecção precoce de doenças em exames de imagem. A aplicação prática desse modelo de Redes Neurais sugere uma melhoria na qualidade e precisão dos diagnósticos por imagem, especialmente em cenários onde a análise manual pode ser desafiadora.

Observa-se que, conforme o número de épocas aumenta, o desempenho da Rede Neural tende a superar o da Lógica de Regressão. No início, com 48,2 épocas, a Rede Neural ainda está abaixo em relação à Lógica de Regressão, que apresenta 15,6 épocas. Entretanto, à medida que as épocas progridem, a Rede Neural passa a mostrar maior eficiência. Por exemplo, com 55,3 épocas, a Rede Neural já está se aproximando da Lógica de Regressão. A partir de 63,9 épocas, a Rede Neural apresenta valores mais altos em comparação com a Lógica de Regressão.

Esses resultados indicam que a Rede Neural possui uma capacidade de aprendizado aprimorada ao longo do tempo e tende a se tornar mais eficaz em problemas complexos onde há um aumento contínuo nas iterações de treinamento. Isso ocorre porque as Redes Neurais são especialmente projetadas para identificar padrões complexos e não lineares, o que as torna particularmente vantajosas em tarefas que exigem uma modelagem mais detalhada e adaptativa dos dados. Portanto, com um número de épocas suficiente, a Rede Neural pode se mostrar mais eficiente e eficaz para cenários onde uma maior precisão é desejada, enquanto a Lógica de Regressão pode atingir um limite de desempenho mais rapidamente.

6 CONCLUSAO

Em conclusão, a pesquisa abordou o impacto da inteligência artificial (IA) no diagnóstico por imagem, destacando tanto os avanços significativos quanto as limitações associadas ao uso de redes neurais e outras técnicas de aprendizado de máquina. Os resultados obtidos a partir das redes neurais mostraram uma acurácia notável de 63,9,4%, superando a técnica de regressão logística, que obteve 58,4%. Esse desempenho reflete a capacidade das redes neurais em identificar padrões visuais complexos em exames de radiografias. Constatou-se, assim, que a IA pode identificar de maneira extremamente precisa diferenças entre imagens com e sem câncer, como evidenciado por Oselame et al. (2017), que demonstraram a eficácia do modelo na detecção de melanoma.

Portanto, embora a IA represente uma ferramenta promissora para aprimorar diagnósticos médicos, sua implementação prática deve ser cuidadosamente validada e ajustada para garantir sua utilização eficaz e ética. A combinação da inteligência artificial com profissionais médicos pode facilitar o diagnóstico por imagem, o que beneficia pacientes e médicos. No entanto, são necessárias mudanças contínuas para garantir que a tecnologia atinja o seu potencial sem comprometer o julgamento clínico. Ventris (2021) acredita que a colaboração entre a IA e a prática médica é crítica para alcançar resultados ideais e beneficiar todas as partes interessadas.

Na medicina, a inteligência artificial tem demonstrado grande potencial, principalmente quando utilizada na análise de big data. Na imagem diagnóstica, esta tecnologia é promissora e oferece a possibilidade de personalização e melhoria do atendimento. Com a ajuda da inteligência artificial é possível fazer um diagnóstico rápido e preciso, importante para atender às necessidades especiais de cada paciente. Um dos principais desafios é garantir que os dados utilizados para treinar o modelo sejam bons e apropriados para representar a diversidade da população de pacientes. Isto é muito importante porque as imagens médicas podem ser diferentes, não só entre diferentes instituições, mas também entre os próprios pacientes, dependendo do equipamento, das condições em que as imagens são obtidas e do processo. Se os modelos de IA forem treinados com disparidade ou inconsistência, eles podem ter problemas gerais que afetam a precisão do diagnóstico.

Além disso, é importante que alguns médicos não queiram aceitar a IA, muitas vezes têm medo de usar a tecnologia para substituir os humanos. julgamento. ou limitar o aconselhamento médico. Também surgem questões éticas, particularmente no que diz respeito à privacidade e segurança das informações de saúde. Para que a IA seja útil na prática médica cotidiana, é importante que pesquisas futuras não apenas aprimorem algoritmos, mas também desenvolvam métodos que garantam a segurança, ética e eficácia da tecnologia, sempre que considerem a importância. o papel da perícia médica e do julgamento. Desta forma, a IA pode ser uma ferramenta útil para padronizar, e não

substituir, o trabalho dos médicos e outros profissionais de saúde, ampliando a sua capacidade de prestar melhor cuidados aos pacientes.

REFERÊNCIAS

AZEVEDO-MARQUES, Paulo Mazzoncini de. Diagnóstico auxiliado por computador na radiologia. *Radiologia Brasileira*, v. 34, n. 1, p. 285-293, 2001.

BARBOSA, R. B.; FERREIRA, R. T.; SILVA, T. M. D. Previsão de variáveis macroeconômicas brasileiras usando modelos de séries temporais de alta dimensão. *Estudos Econômicos* (São Paulo), v. 50, p. 67-98, 2020.

BERCEAN, Bogdan A. et al. Evidence of a cognitive bias in the quantification of COVID-19 with CT: an artificial intelligence randomised clinical trial. *Scientific Reports*, v. 13, n. 1, p. 4887, 2023.

CAMINHA, Wilker et al. Comparativo do percentual de erros em diagnóstico médico entre neurônios naturais e artificiais. São Paulo: Seven Editora, 2023.

CAMINHA, W. J. C. dos; SANTOS, M. R. C. dos; SOUSA, J. de. Desafios jurídicos na aplicação da inteligência artificial com aprendizagem por reforço. São Paulo: Seven Editora, [S.l.], 2023. Disponível em: <https://sevenpublicacoes.com.br/editora/article/view/1420>. Acesso em: 12 dez. 2024.

FONTANA, M. Modelo de predição de dados baseado em redes neurais recorrentes integrado com historiador industrial. *Revista de Engenharia e Tecnologia*, v. 13, n. 4, 2021.

GÉRON, A. *Hands-On Machine Learning with Scikit-Learn and TensorFlow*. São Paulo: Alta Books, 2019.

HARARI, Yuval Noah. *Homo Deus: uma breve história do amanhã*. São Paulo: Companhia das Letras, 2016.

ISOTANI, S.; BITTENCOURT, I. *Mãos à Obra: Aprendizado de Máquina com Scikit-Learn & TensorFlow*. São Paulo: Alta Books, 2015.

ISZCZUK, A. C. D. et al. Evoluções das tecnologias da indústria 4.0: dificuldades e oportunidades para as micro e pequenas empresas. *Brazilian Journal of Development*, v. 7, n. 5, p. 50614-50637, 2021.

KATO, Eva Maria; MARCONI, Marina de Andrade. *Fundamentos de metodologia científica*. 8. ed. São Paulo: Atlas, 2017.

LAKATOS, Eva Maria; MARCONI, Marina de Andrade. *Fundamentos de metodologia científica*. 8. ed. São Paulo: Atlas, 2017.

MATOS, Fernanda Fernandes; SOUZA, Renato Rocha; REIS, Zilma Silveira Nogueira. Análise de dados de saúde: mineração de texto com a utilização do Orange Canvas para exploração da informação. 2019. Disponível em: <https://repositorio.ufmg.br/handle/1843/56724>.

NUNES, L. R. M. et al. Use of ARIMA and SVM for forecasting time series of the Brazilian electrical system. *Research, Society and Development*, v. 12, n. 3, p. e8112340438, 2023. DOI: 10.33448/rsd-v12i3.40438. Disponível em: <https://rsdjournal.org/index.php/rsd/article/view/40438>. Acesso em: 12 dez. 2024.

OSELAME, Gleidson Brandão et al. Software for automatic diagnostic prediction of skin clinical images based on ABCD rule. *Biosci. J.*, p. 1065-1078, 2017.

ROMANOWSKI, Francielle N. de A.; DE CASTRO, Mariane Boaventura; NERIS, Naysa Wink. Manual de tipos de estudos. Anápolis: Centro Universitário de Anápolis, v. 1, p. 0-38, 2019.

SAKURAI, R.; ZUCHI, J. D. As revoluções industriais até a indústria 4.0. *Revista Interface Tecnológica*, v. 15, n. 2, p. 480-491, 2018.

TOSCANO, Wagner. Inteligência Artificial Introdução. ResearchGate, 2009.

VENTRIS, A. C. D. et al. Dados abertos conectados: em busca da web do conhecimento. São Paulo: Novatec Editora, 2021.

WANG, C. et al. Towards Time-Series Feature Engineering in Automated Machine Learning for Multi-Step-Ahead Forecasting. *Engineering Proceedings*, v. 18, n. 1, p. 17, 2022.