

**UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA
GRADUAÇÃO EM ENGENHARIA BIOMÉDICA**

PAULA ASSUNÇÃO

**UTILIZAÇÃO DA INTELIGÊNCIA ARTIFICIAL NO APRIMORAMENTO DA
PREDIÇÃO DE MANUTENÇÃO EM EQUIPAMENTOS MÉDICO-HOSPITALARES**

Uberlândia

2023

Paula Assunção

**UTILIZAÇÃO DA INTELIGÊNCIA ARTIFICIAL NO APRIMORAMENTO DA
PREDIÇÃO DE MANUTENÇÃO EM EQUIPAMENTOS MÉDICO-HOSPITALARES**

Trabalho de Conclusão de Curso
apresentado à Faculdade de Engenharia
Elétrica da Universidade Federal de
Uberlândia como requisito parcial para
obtenção do título de bacharel em
Engenharia Biomédica.

Orientadora: Prof^ª. Dra. Ana Claudia
Patrocínio

Uberlândia

2023

Dedico este trabalho aos meus pais, meus avós, meus irmãos, minhas sobrinhas e à tia Detinha, pelo infinito carinho, suporte e compreensão. Nada disso teria acontecido sem vocês.

AGRADECIMENTOS

Agradeço, em primeiro lugar, a Deus, cuja presença foi a luz que guiou todo o meu percurso. Sua mão esteve presente em cada desafio, revelando-me que tudo acontece no tempo determinado por Sua sabedoria. Sou grata pelos teus planos para minha vida, sempre superando os meus próprios sonhos.

À minha mãe, Ivanilda, por seu apoio incansável, incentivo constante e força nos momentos difíceis. Obrigada por sempre recordar-me do meu valor e da minha capacidade, mesmo nos momentos de desânimo e cansaço.

Ao meu pai, Valter Lucio, sua incansável crença em minha capacidade e seu apoio inabalável foram verdadeiras âncoras nos momentos em que a vida me apresentava dificuldades.

Aos meus avós, Maria e Sebastião, por serem luz na minha vida e modelos a seguir em minha trajetória.

À minha irmã, Bruna, por ajudar até quando eu não sabia que precisava de ajuda e pelo suporte incansável em todos os momentos.

Ao meu irmão, Diego, agradeço pelos estímulos aos estudos e por contribuir para que eu confiasse nas minhas decisões.

À tia Detinha, expresso minha gratidão pelo amor incondicional, que foi um alicerce seguro ao longo dessa jornada.

A presença e afeto de cada um de vocês foram fundamentais para o meu crescimento e superação, e por isso, expresso meu sincero agradecimento.

Às minhas queridas sobrinhas, Maria Júlia e Antonella, que surgiram no meio dessa jornada para me trazer felicidade e muita força.

Aos meus amigos que permaneceram e aos que apareceram, sou grata a cada um de vocês imensamente. Vocês, que foram minha família em Uberlândia, que me deram colo quando precisei e compartilharam tantas lágrimas, sorrisos e experiências únicas! Obrigada por embarcarem nessa jornada junto comigo! Amo todos mais do que posso dizer.

À minha orientadora, Ana, por fornecer todo o auxílio necessário para elaboração deste projeto.

Aos docentes da Universidade Federal de Uberlândia, pela excelência dos ensinamentos ao longo desta enriquecedora jornada acadêmica.

“ Se pudesse desejar algo para mim, não desejaria riqueza nem poder; mas a paixão da possibilidade; desejaria apenas um olho que, eternamente jovem, ardesse de desejo de ver a possibilidade.”

— Sören Kierkegaard, em “O instante”.

RESUMO

A Inteligência Artificial na Saúde passou por uma evolução notável nas últimas três décadas, impulsionada pelo surgimento do Aprendizado de Máquina (ML) e do Aprendizado Profundo (DL). Esta progressão resultou em amplas aplicações, proporcionando uma transição da medicina baseada exclusivamente em algoritmos para uma abordagem de medicina personalizada. A Inteligência Artificial (IA) destaca-se como uma ferramenta transformadora, elevando a precisão diagnóstica, otimizando eficiências nos processos de profissionais de saúde e operações clínicas, facilitando o monitoramento de doenças e tratamentos, e aprimorando a precisão de procedimentos, impactando positivamente os resultados para os pacientes. Este estudo concentra-se na avaliação abrangente da aplicação da Inteligência Artificial na predição da manutenção de equipamentos médico-hospitalares. O objetivo primário é analisar as melhorias potenciais nos processos, os impactos nos custos associados e a contribuição para uma gestão eficiente da Engenharia Clínica. Além disso, aborda os desafios enfrentados e as perspectivas futuras neste cenário em constante evolução. Ao explorar a implementação da Inteligência Artificial nesse contexto específico, o estudo visa oferecer insights para otimizar a operação de equipamentos médicos, considerando aspectos como previsão de falhas, manutenção preditiva e gestão proativa de ativos. Essa abordagem preditiva não só eleva a qualidade dos cuidados de saúde, mas também impacta positivamente a gestão de recursos, promovendo uma abordagem mais proativa e eficaz para manter e aprimorar a infraestrutura médica. No entanto, o futuro da IA na saúde também traz incertezas quanto ao seu impacto abrangente na vida humana. A pesquisa destaca a necessidade de antecipar inovações em desenvolvimento e abordar proativamente questões éticas e práticas que possam surgir nesse cenário dinâmico e transformador.

Palavras-chave: Inteligência Artificial; Manutenção Preditiva; Aprendizado de Máquina; Aprendizado Profundo.

ABSTRACT

The Artificial Intelligence in Healthcare has undergone a remarkable evolution in the last three decades, driven by the emergence of Machine Learning (ML) and Deep Learning (DL). This progression has led to extensive applications, facilitating a shift from medicine solely based on algorithms to a personalized medicine approach. Artificial Intelligence (AI) stands out as a transformative tool, enhancing diagnostic accuracy, optimizing efficiencies in healthcare professionals' workflows and clinical operations, facilitating disease and treatment monitoring, and refining procedure accuracy, thereby positively impacting outcomes for patients. This study focuses on the comprehensive evaluation of the application of Artificial Intelligence in predicting the maintenance of medical-hospital equipment. The primary objective is to analyze potential improvements in processes, the associated cost impacts, and the contribution to efficient Clinical Engineering management. Additionally, it addresses the challenges faced and future prospects in this ever-evolving scenario. By exploring the implementation of Artificial Intelligence in this specific context, the study aims to provide insights to optimize the operation of medical equipment, considering aspects such as fault prediction, predictive maintenance, and proactive asset management. This predictive approach not only enhances the quality of healthcare but also positively impacts resource management, promoting a more proactive and effective approach to maintaining and enhancing medical infrastructure. However, the future of AI in healthcare also brings uncertainties regarding its comprehensive impact on human life. The research emphasizes the need to anticipate developments in progress and proactively address ethical and practical issues that may arise in this dynamic and transformative landscape.

Keywords: Artificial Intelligence; Predictive Maintenance; Machine Learning; Deep Learning.

LISTA DE ILUSTRAÇÕES

Figura 1: Análise de sensibilidade de um dispositivo médico-hospitalar

28

LISTA DE ABREVIATURAS E SIGLAS

ANN	<i>Artificial Neural Network</i>
ANVISA	Agência Nacional da Vigilância Sanitária
ATJ	Artroplastia Total do Joelho
ATQ	Artroplastia Total de Quadril
AUC	Área Sob a Curva
CAD	<i>Computer-Aided Detection</i>
CED	<i>Clinical Engineering Department</i>
CNN	<i>Convolutional Neural Network</i>
COVID-19	<i>corona vírus</i>
DL	<i>Deep Learning</i>
DRGE	Doença do Refluxo Gastroesofágico
DT	<i>Decision Trees</i>
DWT	<i>Discrete Wavelet Transformation</i>
EDM	<i>Entropy Degradation Method</i>
ELA	Esclerose Lateral Amiotrófica
EMR	<i>Electronic Medical Record</i>
FDA	<i>Food and Drug Administration</i>
GA	<i>Genetic Algorithm</i>
IA	Inteligência Artificial
IBM	<i>International Business Machines</i>
IEC	<i>International Electrotechnical Commission</i>
IEEE	Instituto de Engenheiros Eletricistas e Eletrônicos
ISO	<i>International Organization for Standardization</i>
KNN	<i>K - Nearest Neighbors</i>
LLA	Leucemia Linfóide Aguda
LSTM	<i>Long Short Term Memory</i>
MAS	<i>Multi-agent System</i>
ML	<i>Machine Learning</i>
MLP	<i>Multilayer Perceptron</i>
NLP	<i>Natural Language Processing</i>
OMS	Organização Mundial da Saúde
PCA	<i>Principal Component Analysis</i>

RNN	<i>Recurrent Neural Network</i>
ROI	<i>Region of Interest</i>
SVM	<i>Support Vector Machine</i>
TC	Tomografia Computadorizada
US	Ultrassonografia

SUMÁRIO

1. INTRODUÇÃO.....	12
1.1. A HISTÓRIA DA INTELIGÊNCIA ARTIFICIAL.....	12
1.2. A INTELIGÊNCIA ARTIFICIAL APLICADA NA SAÚDE.....	14
1.3. CENÁRIO ATUAL.....	18
1.4. OBJETIVO.....	22
2. DESENVOLVIMENTO.....	24
2.1. APLICAÇÃO DA INTELIGÊNCIA ARTIFICIAL NA MANUTENÇÃO DE EQUIPAMENTOS MÉDICO-HOSPITALARES.....	24
2.2. DIFICULDADES NA GESTÃO DE PARQUES TECNOLÓGICOS E NA ANÁLISE DE DADOS.....	31
3. DISCUSSÕES.....	38
3.1. COMO A INTELIGÊNCIA ARTIFICIAL PODE SER APLICADA PARA AUXILIAR NA GESTÃO DE EQUIPAMENTOS MÉDICOS.....	38
4. FUTURO.....	43
4.1. XAI.....	43
4.2. DESAFIOS.....	44
4.3. PERSPECTIVAS.....	48
5. CONCLUSÃO.....	53

1. INTRODUÇÃO

O presente documento foi desenvolvido no âmbito da unidade curricular Trabalho de Conclusão de Curso em Engenharia Biomédica da Universidade Federal de Uberlândia.

1.1. A HISTÓRIA DA INTELIGÊNCIA ARTIFICIAL

No ano de 1950, Alan Turing propôs o "Teste de Turing" como um método para avaliar se uma máquina pode demonstrar comportamento inteligente que seja indistinguível do comportamento humano. Apesar de continuar a ser um tema de debate, o teste teve um grande impacto no campo da Inteligência Artificial (IA) e foi descrito seis anos depois por John McCarthy como "a ciência e a engenharia de criar máquinas inteligentes" [1]. McCarthy teve uma influência significativa nos estágios iniciais do desenvolvimento da Inteligência Artificial, e com seus colegas, inaugurou oficialmente o campo da IA em 1956 durante uma conferência realizada no *Dartmouth College*. A conferência deu início a uma nova área de pesquisa interdisciplinar e estabeleceu uma base intelectual para todos os esforços subsequentes de pesquisa e desenvolvimento de computadores [2].

A Inteligência Artificial teve suas origens em um conjunto inicial de regras simples do tipo "*if, then*", mas, ao longo das décadas, os rápidos avanços tecnológicos levaram a IA a evoluir para sistemas cada vez mais complexos, aproximando-se da complexidade do cérebro humano [1].

Com essa expansão, foram criadas diversas subáreas da Inteligência Artificial, tais como o Aprendizado de Máquina (*Machine Learning*), o Aprendizado Profundo (*Deep Learning*) e a área de Visão Computacional (*Computer Vision*) [1]. A Aprendizagem de Máquina consiste em utilizar características específicas para reconhecer padrões passíveis de serem empregados na análise de uma situação específica. Isso significa que a máquina adquire a capacidade de aplicar essas informações em situações futuras semelhantes. Na área da medicina, é possível utilizar essa ferramenta de previsão de forma dinâmica na hora de tomar decisões clínicas, adaptando assim o atendimento ao paciente de maneira personalizada, ao invés de seguir um algoritmo fixo [3]. Existem três tipos de ML:

- (i) não supervisionados (capacidade de encontrar padrões);
- (ii) supervisionado (algoritmos de classificação e predição baseados em exemplos anteriores);

(iii) aprendizagem por reforço (uso de sequências de recompensas e punições para formar uma estratégia para operação em um espaço de problema específico).

O Aprendizado de Máquina (ML) progrediu em direção ao que é amplamente conhecido como Aprendizado Profundo (DL). Essa abordagem consiste em utilizar algoritmos para desenvolver uma Rede Neural Artificial (ANN) que consegue aprender e tomar decisões de forma autônoma, assim como o cérebro humano. A Visão Computacional refere-se à habilidade dos computadores em adquirir informações e compreender imagens e vídeos, permitindo assim que realizem tarefas que geralmente seriam dependentes da capacidade humana de processar informações visuais [1].

Nos anais da história industrial, um momento crucial ocorreu em 1961 com a introdução do primeiro braço robótico numa linha de montagem da *General Motors*. Esta criação revolucionária, chamada *Unimate*, surpreendeu o mundo ao executar comandos passo a passo com perfeição. Seu advento sinalizou uma mudança monumental em direção à fabricação automatizada e preparou o terreno para uma profunda transformação na indústria. Apenas alguns anos depois, em 1964, Joseph Weizenbaum apresentou Eliza, um programa inovador de processamento de linguagem natural que empregava correspondência e substituição de padrões para iniciar conversas semelhantes às humanas. Esta conquista notável lançou as bases para o desenvolvimento subsequente de *chatbots* e sistemas de diálogo automatizados. Então, em 1966, Shakey emergiu como a “primeira pessoa eletrônica”, um robô móvel inovador desenvolvido no prestigiado *Stanford Research Institute*. A capacidade de Shakey de interpretar instruções e responder de acordo representou um salto significativo no sentido de estabelecer a autonomia das entidades robóticas [1].

Apesar das inovações na engenharia, a integração da inteligência artificial (IA) no campo da medicina tem sido notavelmente lenta. No entanto, avanços significativos foram feitos durante esta fase inicial de implementação, que posteriormente serviram de base para o crescimento futuro e utilização da AIM (Inteligência Artificial na Medicina). O Sistema de Análise e Recuperação de Literatura Médica (MEDLARS – *Medical Literature Analysis and Retrieval System*) e a plataforma de busca PubMed pela Biblioteca Nacional da Medicina tornaram-se posteriormente recursos importantes para acelerar a biomedicina na década de 1960. Além disso, o desenvolvimento de bancos de dados de informática clínica e de registros de sistemas médicos durante este período desempenhou um papel crucial na definição do futuro da IA na medicina [1].

O período que se estende de 1970 a 2000, conhecido como o "inverno da IA", testemunhou um declínio no financiamento e no interesse na área, levando a uma escassez de

avanços notáveis. Esta era pode ser dividida em dois períodos distintos de "inverno": o primeiro ocorrendo no final dos anos 1970 devido às percepções das limitações da IA, e o segundo no final dos anos 1980 até o início dos anos 1990, devido aos custos exorbitantes associados ao desenvolvimento e manutenção de bases de dados de informações digitais especializadas [1].

No entanto, após este período de desaceleração, emergiu uma nova era de progresso com o uso de mineração de dados logísticos e diagnósticos médicos, seguidos pelo desenvolvimento de instrumentos com grande poder computacional.

1.2. A INTELIGÊNCIA ARTIFICIAL APLICADA NA SAÚDE

A Inteligência Artificial na Saúde, também conhecida como Inteligência Artificial na Medicina (AIM) passou por avanços significativos nas últimas 3 décadas. Desde o advento do Aprendizado de Máquina (ML) e do Aprendizado Profundo (DL), suas aplicações expandiram-se, criando oportunidades para a medicina personalizada, em vez de depender apenas de algoritmos [1].

Para implementar os sistemas de Inteligência Artificial em contextos de saúde, é necessário treiná-los utilizando dados originados de atividades clínicas, incluindo triagem, diagnóstico, prescrição de tratamentos, entre outras. Isso permite que esses sistemas identifiquem padrões similares entre os pacientes e estabeleçam conexões entre as características dos pacientes e os resultados relevantes [4]. Estes dados clínicos são variados e incluem informações demográficas, registros médicos, dados de dispositivos médicos eletrônicos, resultados de exames físicos e laboratoriais, bem como imagens. No estágio de diagnóstico, há uma extensa revisão da literatura que abrange dados provenientes de exames de imagem, testes genéticos e eletrodiagnósticos.

No entanto, certas observações clínicas, frequentemente apresentadas em formato de texto não estruturado, como imagens ou dados genéticos e eletrofisiológicos, não podem ser diretamente analisadas por Inteligência Artificial. Para resolver isso, as aplicações correspondentes de IA inicialmente se concentram em converter esse texto não estruturado em Registros Médicos Eletrônicos (EMR) compreensíveis para máquinas.

Nesse contexto, o advento da Inteligência Artificial (IA) emerge como uma ferramenta capaz de aprimorar significativamente a precisão dos diagnósticos, otimizar a eficiência nos fluxos de trabalho dos profissionais de saúde e nas operações clínicas. Também, permite o

monitoramento contínuo de doenças e tratamentos, bem como melhora a precisão dos procedimentos e os resultados gerais para os pacientes [1].

Em 1970, foi introduzido o sistema de IA denominado MYCIN, que se baseava nas contribuições dos médicos e numa vasta base de conhecimento composta por 600 regras para identificar com precisão potenciais bactérias nocivas e fornecer recomendações personalizadas de antibióticos, tendo em conta o peso corporal do paciente. Esse pioneiro sistema de IA serviu como a base para o desenvolvimento posterior do EMYCIN, um sistema baseado em regras. Além disso, o INTERNIST-1 foi posteriormente criado, seguindo a mesma estrutura do EMYCIN, mas com uma base de conhecimento médico mais abrangente, para auxiliar no diagnóstico de cuidados primários.

Um dos primeiros protótipos a demonstrar o potencial de aplicação da IA à medicina foi um programa de consulta para glaucoma usando o modelo *CASNET*, desenvolvido na *Rutgers University* e oficialmente demonstrado no encontro da Academia de Oftalmologia de 1976 em Las Vegas, Nevada. O modelo *CASNET* é uma rede causal-associacional que abrange três programas separados: construção de modelo, consulta e um banco de dados criado e mantido pelos colaboradores. Este modelo podia aplicar informações sobre uma doença específica a pacientes individuais e fornecer aos médicos conselhos sobre o manejo de pacientes [1].

No ano de 1986, a Universidade de Massachusetts apresentou o *DXplain*, um sistema de apoio à tomada de decisões médicas. Este programa não só gera diagnósticos com base nos sintomas inseridos, mas também serve como um livro médico eletrônico, oferecendo descrições meticulosas de doenças e informações complementares, além de informações suplementares. Inicialmente equipado com conhecimento relativo a aproximadamente 500 doenças, o banco de dados do *DXplain* cresceu exponencialmente, abrangendo agora mais de 2.400 condições médicas [1].

Em 1992, o sistema *ROBODOC* (desenvolvido pela *Curexo Technologies*, localizada em Fremont, Califórnia, EUA) se tornou um marco significativo como o pioneiro na aplicação de sistemas robóticos em cirurgia ortopédica [5]. Esse sistema possibilitou aos cirurgiões o planejamento preciso do posicionamento dos componentes femorais, oferecendo um auxílio proveitoso na realização de cirurgias de artroplastia total de quadril (ATQ) não cimentada. No entanto, a adoção desta tecnologia inicialmente encontrou algumas limitações devido à sua complexidade técnica, ao aumento do tempo cirúrgico e à sua relativa falta de versatilidade.

Outro avanço notável veio com o *CASPAR* (desenvolvido pela *OrthoMaquet/URS*, com sede em Schwerin, Alemanha), que representa um dos primeiros sistemas autônomos neste contexto. Este sistema, guiado por imagens, se comportava como um robô ativo e obteve

sucesso em procedimentos de artroplastia total do quadril (ATQ) e artroplastia total do joelho (ATJ), semelhantemente ao *ROBODOC* [6].

Em 2007, a IBM introduziu um sistema de atendimento automático de domínio aberto chamado *Watson*, que competiu com participantes humanos e conquistou a primeira colocação no popular programa de televisão *Jeopardy!*, em 2011. Diferentemente dos sistemas convencionais que empregavam lógica direta, lógica reversa ou regras de "if-then" predefinidas, essa inovação tecnológica conhecida como *DeepQA*, utilizou o processamento de linguagem natural e uma ampla pesquisa para analisar dados não estruturados e gerar respostas baseadas em evidências. Este sistema se destacou por ser mais acessível, mais simples de manter e economicamente vantajoso. Ao extrair informações dos prontuários eletrônicos dos pacientes e outras fontes eletrônicas, a tecnologia *DeepQA* foi aplicada com sucesso para fornecer respostas embasadas em evidências no campo da medicina [1].

Em 2017, *Watson* foi aplicado de maneira eficaz para identificar novas proteínas de ligação ao RNA que apresentaram alterações na esclerose lateral amiotrófica (ELA) [1]. Seu sistema incluiu módulos de ML e Processamento de Linguagem Natural (NLP) e também fez progressos promissores na oncologia. Em uma pesquisa sobre câncer, 99% das recomendações de tratamento do *Watson* são coerentes com as decisões do médico, além de ter colaborado com a *Quest Diagnostics* para oferecer a Análise de Diagnóstico Genético de IA.

Com os avanços em computadores, programas de *hardware* e *software*, a medicina digitalizada tornou-se prontamente mais acessível, impulsionando o crescimento acelerado da Inteligência Artificial em Medicina (AIM). Este avanço provocou mudanças significativas na forma como pacientes e profissionais de saúde interagem com a informação médica e os processos clínicos [1].

O Processamento de Linguagem Natural (NLP) revolucionou a interação com *chatbots*, elevando-os de simples ferramentas de comunicação para interfaces de conversação mais significativas. Esta tecnologia inovadora na área da saúde deu origem ao *Pharmabot*, um *chatbot* desenvolvido em 2015 com o propósito de fornecer educação sobre medicamentos para pacientes pediátricos e seus pais, e em 2017 surgiu *Mandy*, uma solução automatizada para a admissão de pacientes em clínicas de cuidados primários [7,8].

O Aprendizado Profundo (DL) também representou um avanço crucial na Inteligência Artificial em Medicina (AIM). Em contraste com o Aprendizado de Máquina (ML), que depende de um conjunto predefinido de características e frequentemente requer intervenção humana, o DL consegue aprender e classificar seus próprios dados de forma autônoma.

Embora o DL tenha sido inicialmente explorado na década de 1950, sua aplicação na medicina foi inicialmente limitada por um desafio conhecido como "*overfitting*". O *overfitting* ocorre quando um modelo de ML se ajusta excessivamente a um conjunto de dados específico e, como resultado, tem dificuldade em generalizar para novos conjuntos de dados. Isso muitas vezes se deve à falta de capacidade computacional suficiente e à escassez de dados de treinamento. No entanto, essas limitações foram superadas na década de 2000, graças à disponibilidade de conjuntos de dados mais amplos e ao notável avanço na capacidade computacional [1].

Na área de processamento de imagens, o avanço da IA se deu através da Rede Neural Convolutiva (CNN), e obteve um avanço no campo da radiologia, uma das áreas de maior utilidade no apoio à decisão médica. Pesquisadores comprovam a eficácia dos algoritmos de Aprendizado Profundo (DL) para a interpretação de imagens radiológicas quando comparados a especialistas humanos. Além disso, um estudo, por meio de uma abordagem nova, totalmente automática e interpretável, identificou o desenho de uma artroplastia total do quadril a partir de radiografias simples via CNN com uma precisão mais alta e com custos com cuidados de saúde reduzidos [9].

Nas aplicações da Inteligência Artificial na Saúde, dentre as várias vertentes importantes, há o Processamento de Linguagem Natural (NLP). Os procedimentos da NLP extraem informações de dados não estruturados, como notas clínicas e de revistas médicas para complementar e enriquecer dados médicos, visando transformar todo o conteúdo em textos estruturados legíveis pela máquina, para que os algoritmos de ML possam ser executados diretamente após processos adequados de pré-processamento ou controle de qualidade. A estrutura do NLP compreende dois componentes principais: (1) processamento de texto e (2) classificação. Através do processamento de texto, a NLP identifica uma série de palavras-chave relevantes de doenças nas notas clínicas com base no histórico de bancos de dados. Em seguida, um subconjunto de palavras-chave é selecionado examinando seus efeitos na classificação entre os casos normais e anormais. As palavras-chave validadas em seguida, são inseridas de modo a enriquecer os dados estruturados para apoiar a tomada de decisões clínicas. Essa estrutura de NLP foi desenvolvida para auxiliar na tomada de decisões clínicas sobre alerta de arranjos de tratamento, monitorar efeitos adversos e assim por diante [4].

Diante disso, a Inteligência Artificial não apenas otimiza diagnósticos médicos, mas também desempenha um papel fundamental na personalização dos tratamentos. A capacidade da IA em analisar grandes conjuntos de dados de pacientes, combinada com algoritmos avançados, permite a identificação de padrões e tendências para aprimorar as estratégias

médicas. Ao fazer isso, a integração da Inteligência Artificial na saúde não apenas eleva o nível do atendimento, mas também contribui para a evolução contínua da prática médica, proporcionando uma abordagem mais assertiva e centrada no paciente. Nesta condição, a IA emerge como uma aliada promissora na busca por avanços significativos na área da saúde, promovendo uma medicina mais eficaz, personalizada e adaptada às demandas específicas de cada indivíduo.

1.3. CENÁRIO ATUAL

Ao longo da história, desde a criação da IA, dentre suas inúmeras aplicações, a mesma é utilizada na medicina para melhorar a precisão, a consistência e eficiência do atendimento ao paciente. Atualmente, é considerada um ramo da engenharia que implementa novos conceitos e soluções inovadoras para resolver desafios complexos. Sua aplicação gerou grandes mudanças em toda a área da saúde, revisitando a discussão sobre a substituição de médicos por “robôs” [3].

A utilização da IA na saúde reflete o pensamento sistêmico atual sobre cuidados de saúde, pois não se concentra somente na relação médico-paciente, mas sim na organização hospitalar na totalidade. Esse sistema parte da premissa de que o sistema de saúde não deve ser estacionário, mas deve aprender com suas próprias experiências e se esforçar em implementar melhorias contínuas em todos os processos. Este sistema é chamado de Sistema Multiagente (MAS), onde um conjunto de agentes situados em um ambiente comum interagem entre si. Este processo envolve a construção de uma organização, que usa IA para alcançar um progresso significativo [3].

Guiado por relevantes questões clínicas, técnicas poderosas de IA podem desbloquear informações clinicamente relevantes ocultas em uma enorme quantidade de dados, no que lhe concerne, podem auxiliar na tomada de decisão clínica. Todas as informações, resultados de exames físicos, testes laboratoriais e dados do paciente, independentemente de estarem na faixa de normalidade ou apresentarem anormalidades, são tratadas como dados. A expressão "*big data*" é reservada para descrever conjuntos de dados que são tão extensos ou complexos que não podem ser processados eficazmente por métodos de análise de dados convencionais, logo, uma análise precisa e o uso eficaz desses dados são de importância crucial na adaptação e na aplicação de tratamentos. No entanto, uma vez que é humanamente impossível processar

conjuntos de dados dessa magnitude, a interpretação dos dados está, cada vez mais, sendo realizada por processadores mais hábeis, que continuam a ganhar velocidade diariamente [4].

Na literatura, apesar de cada vez mais rica sobre IA na área da saúde, a pesquisa se concentra principalmente em algumas doenças como: câncer, doenças do sistema nervoso e doenças cardiovasculares. O foco nessas três condições se dá por liderarem as causas de morte mundialmente, tornando o diagnóstico precoce essencial para prevenir a deterioração da saúde dos pacientes. Além disso, os aprimoramentos nos métodos de análise por imagem, genética, exames e Registros Médicos Eletrônicos (EMR) - áreas nas quais a IA se destaca - têm o potencial de possibilitar diagnósticos mais rápidos [4].

A tecnologia R2 liderou a inovação ao introduzir o *Computer-Aided Detection* (CAD) na mamografia em 1998 nos Estados Unidos sendo aprovado pela *Food and Drug Administration* (FDA) para mamografia de rastreamento, marcando um marco significativo com o sistema *ImageChecker CAD*. Além disso, foi o primeiro a receber aprovação para uso em mamografia digital. Já *SecondLook* (*iCAD Systems*; Canadá) obteve aprovação da FDA em 2001 para mamografias digitais, seguida por outros sistemas mais recentes no mercado [10,11].

Já em 2017, houve a criação do aplicativo *Arterys* e seu notável primeiro produto: o *CardioAI*, que pôde analisar imagens de ressonância magnética cardíaca em questão de segundos. Desde então, sua atuação expandiu para incluir imagens de fígado e pulmão, tórax e imagens de radiografia musculoesquelética e tomografia computadorizada de crânio sem contraste imagens. Através do uso de DL, essas imagens podem ser interpretadas de forma mais eficaz para identificar anomalias, auxiliar na segmentação de estruturas e fornecer informações valiosas aos médicos [1].

O diagnóstico assistido por computador também se aplica na gastroenterologia. Alguns exemplos são: utilização da IA para auxiliar na diferenciação entre pancreatite crônica e o câncer pancreático, um desafio clínico comum; DL para realizar modelos de predição para prognóstico e resposta a tratamentos, etc. Há também estudos de RNAs criados e testados para diagnóstico e previsão de modelos em gastroenterologia. Em um estudo retrospectivo de 150 pacientes, 45 variáveis clínicas foram utilizadas para fazer um diagnóstico de DRGE (doença de refluxo gastroesofágico) com 100% de acurácia [1]. Na área da endoscopia, a IA também possui uma perspectiva promissora. Suas aplicações iniciais envolvem o uso de programas auxiliados por computador para diagnosticar, diferenciar e caracterizar pólipos no cólon, sejam eles neoplásicos ou não [8], melhoria na imagem da doença de Esôfago de

Barrett [12], detecção de anomalias endoscópicas no intestino delgado [13] e câncer gástrico [14].

No caso de câncer de mama, o processo pode ser analisado em três etapas fundamentais: pré-processamento, extração de atributos e classificação. A etapa de extração de recursos desempenha um papel crucial, por contribuir para a discriminação entre tumores benignos e malignos. Propriedades da imagem, como suavidade, aspereza, profundidade e regularidade, são extraídas por meio de técnicas de segmentação, proporcionando informações essenciais para a análise e interpretação das imagens mamográficas [15].

Em casos que envolvem câncer de pulmão, onde os sintomas evidentes em estágios iniciais são muitas vezes indetectáveis, os laudos de tomografia computadorizada (TC) oferecem informações mais nítidas em comparação com relatórios de ressonância magnética e raios X. Diversas técnicas, como conversão de escala de cinza, redução de ruído, binarização e segmentação, são empregadas para obter imagens com menos ruídos e menos distorcidas. Para a detecção do câncer de pulmão de pequenas células (SCLC), há um desafio para o olho humano, por ser quase indistinguível do tecido normal. No entanto, os algoritmos de Aprendizado de Máquina, especificamente as Redes Neurais de Convolução (CNN), desempenham um papel crucial na resolução desse problema.

Para superar a necessidade de grandes conjuntos de dados de treinamento, é possível recorrer a Método de Degradação de Entropia (EDM), que utiliza alta resolução de tomografias computadorizadas pulmonares para converter histogramas vetorizados em pontuações e, em seguida, transformar essas pontuações em probabilidades por meio de uma função logística. Nessa abordagem, a detecção de SCLC é tratada como um problema binomial, distinguindo entre uma pessoa saudável e uma pessoa com câncer de pulmão. Embora razoavelmente precisa, há espaço para melhorias, especialmente ao expandir o conjunto de treinamento e aprofundar a rede. A integração com CNN aprimora ainda mais o processamento de imagens, proporcionando uma detecção mais eficiente em aplicações de imagens de TC [16].

A Leucemia Linfoblástica Aguda (LLA) é um tipo de câncer caracterizado pelo rápido desenvolvimento de inúmeras células linfocitárias imaturas, impactando a produção de outras células sanguíneas. Diversos algoritmos de aprendizado de máquina são utilizados para a detecção de leucemia, incluindo *K - Nearest Neighbors* (KNN), *Support Vector Machine* (SVM), Redes Neurais com Função de Ativação de Base Radial (RBFN) e Perceptron Multicamada (MLP). Todas essas abordagens compartilham basicamente quatro etapas

principais: pré-processamento, extração de atributos, construção do modelo de classificação e avaliação do classificador [17].

No campo da cardiologia, a Inteligência Artificial desempenha um papel crucial em diversas frentes. Destacam-se, entre essas, a personalização de tratamentos para correção do ritmo cardíaco, a consideração de diferenças de gênero que impactam os desfechos de doenças cardiovasculares e avanços em genômica. No contexto específico dos exames de sangue, amplamente utilizados na cardiologia, a atenção se concentra principalmente na pesquisa genética, buscando identificar causas genéticas subjacentes às doenças. A medicina de precisão em cardiologia se vale de diversos métodos diagnósticos e terapêuticos, incluindo exames de sangue, testes genéticos e de imagem, muitas vezes combinados para uma abordagem mais abrangente. Técnicas avançadas de Aprendizado de Máquina, como CNN, Rede Neural Recorrente (RNN), Processamento Natural de Linguagem (NLP), SVM e Memória de Longo e Curto Prazo (LSTM), são empregadas no desenvolvimento de Sistemas de Suporte à Decisão Clínica (CDSS) que se baseiam em Aprendizado Profundo [18].

A aplicação do Aprendizado de Máquina para identificação de problemas cardiológicos segue uma abordagem que engloba pré-processamento, seleção criteriosa de recursos, métodos de validação cruzada, utilização de classificadores de Aprendizado de Máquina e avaliação de desempenho do classificador [19].

Os pesquisadores estudam também aplicações na Doença de Parkinson, inserida na categoria de doenças neurodegenerativas que podem afetar as células cerebrais de forma direta ou indireta, resultando em desafios relacionados ao movimento, fala e outras funções cognitivas. Utilizando algoritmos de Aprendizado de Máquina, eles aplicam técnicas de gravação de vídeo e visão computacional para distinguir entre pacientes controle saudáveis e aqueles diagnosticados com Parkinson. Além disso, alguns estudiosos exploram amostras de voz como uma ferramenta eficaz na diferenciação entre pacientes saudáveis e portadores de DP [20].

No ambiente da Engenharia Clínica, pesquisadores utilizaram uma amostra de dados de manutenção corretiva ou solicitação de serviço de um hospital com 416 dispositivos médicos localizados em nove áreas piloto. É importante salientar que quando todo o conjunto de dados de equipamentos médicos e transações de manutenção são analisados, mais *insights* relacionados a solicitações de serviço e falhas de equipamento podem ser encontrados. Contudo, é uma prática comum para reduzir o conjunto de dados utilizar uma amostra de dados representativa usando um método probabilístico ou não probabilístico. Esses pesquisadores concluíram que as causas predominantes das solicitações de serviço incluíam

políticas de manutenção mal programadas, falta de orientação e treinamento para os usuários, além de falhas intrínsecas nos dispositivos médicos.

Por meio do agrupamento, identificou-se que as principais causas de falhas reais estavam relacionadas aos sistemas de abastecimento de água e vapor, juntamente com um padrão de solicitação de serviço "não real" (erros do usuário) pela manhã. Esta descoberta recebeu atenção especial, resultando em ajustes tanto na estrutura de treinamento operacional dos usuários quanto nas políticas de manutenção programada. A análise destacou um método eficaz para avaliar a qualidade dos serviços hospitalares, fornecendo *insights* sobre áreas de aprimoramento e um modelo para avaliar a eficácia dessas melhorias.

O estudo ilustrou a aplicação bem-sucedida de "técnicas inteligentes", como a *Association Discovery & Clustering Techniques*, para otimizar o desempenho do Departamento de Engenharia Clínica (CED), dada sua importância para a qualidade dos cuidados de saúde e os resultados financeiros em ambientes de saúde. Os autores enfatizam a relevância desta contribuição e incentivam a adoção de abordagens semelhantes em outras áreas, além das discutidas no estudo [21].

Em síntese, o interesse dos cirurgiões da nova geração pela tecnologia e o crescente fluxo de dados servem como provas convincentes de que estes sistemas desempenharão um papel cada vez mais significativo no planejamento e implementação da IA nos hospitais. Espera-se que a mesma seja sempre utilizada com eficiência e como mecanismo de auxílio, podendo eliminar fatores de risco e erros causados por humanos. Prevê-se que a sua utilização seja eficaz e de apoio, mitigando os potenciais riscos e erros associados à intervenção humana. É importante ressaltar que estes avanços tecnológicos são concebidos para colaborar com os médicos, em vez de suplantá-los, promovendo assim uma parceria harmoniosa que prioriza o bem-estar dos pacientes.

1.4. OBJETIVO

O presente estudo visa realizar uma avaliação da aplicação da Inteligência Artificial na predição da manutenção de equipamentos médico-hospitalares. Com a análise das potenciais melhorias nos processos, os impactos nos custos associados, a contribuição para a gestão eficiente da Engenharia Clínica, além de abordar os desafios enfrentados e as perspectivas futuras.

Objetivos Específicos:

- Explorar o emprego da Inteligência Artificial nesse contexto específico;
- Fornecer informações para a otimização da operação de equipamentos médicos, considerando aspectos como a previsão de falhas, a manutenção preditiva e a gestão proativa de ativos;
- Avaliar os efeitos dessa abordagem na eficiência operacional, nos custos associados aos serviços de manutenção e na tomada de decisões estratégicas na Engenharia Clínica;
- Compreender o real impacto dessa inovação tecnológica.

2. DESENVOLVIMENTO

Neste capítulo, são apresentados os conceitos teóricos acerca de questões, desafios e afirmativas importantes para exemplificar o objetivo deste trabalho. Inicialmente, foi estudada a aplicação da Inteligência Artificial na área de manutenção de equipamentos médico-hospitalares, as dificuldades da gestão de parques tecnológicos (manutenções) e da análise de dados. Em seguida, foram apresentadas gestões de parques tecnológicos sem o uso de Inteligência Artificial.

2.1. APLICAÇÃO DA INTELIGÊNCIA ARTIFICIAL NA MANUTENÇÃO DE EQUIPAMENTOS MÉDICO-HOSPITALARES

No ambiente hospitalar, os equipamentos médico-hospitalares são essenciais para o diagnóstico, tratamento, prevenção e reabilitação de doenças, sendo de suma importância que ofereçam aos pacientes um serviço de qualidade e segurança, atendendo às exigências da ANVISA. Garantir a confiabilidade, facilidade de manutenção, disponibilidade e segurança dos dispositivos médicos é o principal objetivo na estratégia de manutenção. Nesse cenário, os equipamentos recebem três tipos de manutenção:

(i) Corretiva: ocorre após uma falha, dano ou erro no equipamento. O principal objetivo é fazer com que a região ou peça volte a funcionar adequadamente, e em caso de erro, seja solucionado;

(ii) Preventiva: ocorre em intervalos pré-determinados (a variar conforme o equipamento). O principal objetivo é impedir falhas antes que ocorram, aumentando assim a vida útil do equipamento;

(iii) Preditiva: é o acompanhamento do funcionamento do equipamento por medições e coleta de dados em um intervalo de tempo regular a fim de monitorar suas condições mecânicas, eletrônicas, pneumáticas, elétricas, etc. Esse tipo de manutenção auxilia na tomada de decisões para programar manutenções corretivas e preventivas nos intervalos corretos.

Deste modo, é crucial que esses dispositivos não apresentem falhas com frequência e, caso ocorram, sejam reparados imediatamente. Estudos relacionam falhas em dispositivos médicos a lesões graves em pacientes e, em alguns casos, até mesmo a óbitos [22,23].

A OMS calcula que 50% a 80% dos dispositivos não operam adequadamente devido à ausência de uma cultura voltada para a manutenção, falta de habilidades técnicas e uma

preferência por solucionar problemas apenas após a ocorrência, em vez de adotar medidas preventivas. Uma manutenção ineficaz de dispositivos médicos conseqüentemente causa maior tempo de inatividade, diminuição do desempenho do dispositivo, desperdício monetário e esgotamento de recursos. Este tipo de manutenção se caracteriza por diversos fatores, como armazenamento e transporte inadequados, falha inicial, manuseio incorreto, manutenção inadequada, uso de materiais não originais, peças sobressalentes ou peças sobressalentes recondiçionadas, estresse ambiental, técnica de reparo imprópria e falhas por desgaste [24].

Estima-se que 1,5 milhão de dispositivos médicos exclusivos estão registrados globalmente. As despesas com dispositivos médicos aumentaram de 145 milhões de dólares em 1998 para 220 milhões de dólares em 2006, indicando uma taxa de crescimento anual superior a 10% [25]. Conseqüentemente, o mercado de manutenção de dispositivos médicos experimentou um crescimento devido à crescente importância dada ao diagnóstico precoce, ao aumento dos procedimentos de diagnóstico por imagem, à presença de vários fabricantes de equipamentos originais e às estratégias de parceria e colaboração entre prestadores de serviços e usuários finais.

Os fabricantes ou seus representantes autorizados são responsáveis por assegurar a disponibilidade do serviço técnico ao longo do ciclo de vida do dispositivo, sendo o papel do serviço de pós-venda fundamental na resolução de problemas durante falhas, fornecendo acesso a peças de reposição, componentes desgastados e orientações técnicas. Durante o processo de aquisição, os usuários e os departamentos de compras costumam negociar com os fornecedores de dispositivos médicos um período de garantia que inclui esse tipo de serviço. Paralelamente, o fabricante emite uma carta de descontinuação para notificar os clientes caso o modelo seja retirado de circulação nesse intervalo. Nesse momento, os usuários são orientados a substituir ou atualizar os dispositivos médicos conforme necessário.

Devido ao grande número de dispositivos utilizados nos ambientes hospitalares, os gestores desses locais vêem uma necessidade de redução das despesas de manutenção, mas garantindo a confiabilidade do equipamento e, obviamente, prolongando a funcionalidade e a vida útil do mesmo [25]. Mas, além das questões relacionadas à manutenção dos equipamentos, há também questões relativas à segurança e confiabilidade destes dados, a constante busca por um atendimento de excelência à equipe do hospital e aos pacientes, ao fluxo de trabalho caro e a ineficiência de processos dispendiosos.

Para atender as demandas crescentes dos serviços de saúde, torna-se necessário uma análise minuciosa dos processos para eliminar etapas desnecessárias e simplificar o fluxo de trabalho. Nesse contexto, a Inteligência artificial (IA) é um dos principais componentes de um

trabalho eficiente e emergiu como uma ferramenta promissora para auxiliar os seres humanos em diversas situações, até em momentos de crise, como ocorreu na pandemia da COVID-19 [19].

O Aprendizado de Máquina (ML) atua realizando o pré-processamento, extração de características e, juntamente com a Análise de Componentes Principais (PCA) e outros algoritmos, geram um conjunto de recursos para classificação de dados [19]. Além disso, a IA também é utilizada para privacidade e questões de segurança, apesar dos inúmeros desafios encontrados, os quais serão discutidos posteriormente. Esses modelos preditivos, ao serem utilizados para o gerenciamento inteligente de saúde, necessitam de melhorias devido à diversidade de dispositivos médicos com os quais irão atuar, para que os dados fiquem estruturados visando uma melhor precisão nos resultados, mas ainda existem algumas lacunas, como as identificadas por Rahman [26]:

i) Até abril de 2023, apenas três pesquisas haviam explorado o uso de Inteligência Artificial em dispositivos médicos para prever seu desempenho. Estes estudos criaram modelos preditivos examinando apenas dados históricos de três tipos de dispositivos: incubadoras infantis, bombas de infusão e desfibriladores. Ainda não foram realizadas avaliações abrangentes sobre a confiabilidade destes dispositivos médicos, e os custos da análise não foram incluídos nas avaliações;

ii) Os estudos sobre a confiabilidade de dispositivos médicos foram agrupados em três principais áreas: avaliação de riscos, previsão de desempenho ou falhas e gerenciamento do sistema. A maioria dessas pesquisas se concentra na gestão de riscos, utilizando análise de códigos de falha e priorização de manutenção em suas avaliações de confiabilidade. As aplicações de IA para o gerenciamento e monitoramento, que poderiam aproveitar a vasta quantidade de dados disponíveis, são limitadas e não foram exploradas adequadamente pela falta de um modelo que preveja a probabilidade de falha dos equipamentos;

iii) Três pesquisas sobre previsão de desempenho em dispositivos médicos utilizando Inteligência Artificial foram identificadas. O modelo prevê o desempenho dos dispositivos médicos ao analisar dados precisos e defeituosos, classificando-os com base na resposta de aprovação ou reprovação. A prática atual envolve manutenções preventivas programadas, seguindo a frequência sugerida pelo fabricante, sem considerar o histórico de falhas.

O estudo preenche uma lacuna na pesquisa científica ao desenvolver um modelo preditivo para dispositivos médicos críticos e tem a capacidade de prever a probabilidade de falha do dispositivo com base na data de compra, classificando-o em três categorias: (i) Classe 1, onde é improvável que o dispositivo falhe nos primeiros 3 anos após a compra; (ii) Classe

2, onde o dispositivo provavelmente falhará dentro de 3 anos a partir da data de compra; e (iii) Classe 3, onde o dispositivo provavelmente falhará mais de 3 anos após a compra. O estudo compara modelos de Aprendizado de Máquina (ML) e Aprendizado Profundo (DL) com o objetivo de determinar as necessidades reais do cronograma de manutenção e estabelecer um gerenciamento de manutenção estratégico abrangente para reduzir os custos operacionais e de manutenção.

O modelo proposto por Rahman [26] usando IA categorizou os dispositivos médicos em classes: 1, 2 e 3; e utilizou outros elementos, como *recall*, precisão, especificidade, pontuação F1 e Área Sob a Curva (AUC). Abrangeu 44 tipos de dispositivos médicos críticos encontrados em cinco categorias hospitalares, envolvendo 15 unidades de saúde e incluindo todos os dispositivos cruciais utilizados na área clínica para pacientes.

A classe 1, com zero falhas, representa dispositivos menos críticos, enquanto a classe 2 é identificada como a mais crucial, com a primeira falha ocorrendo nos primeiros 3 anos após a compra. Já a classe 3 apresenta um risco médio, com dispositivos propensos a falhas após 3 anos.

Durante a fase de treinamento foram utilizados dados de dispositivos médicos ativos, incluindo informações sobre custos de manutenção, além de dispositivos com mais de 20 anos de instalação, totalizando uma amostra de 8.294 dispositivos. Esse conjunto de dados resultou em uma precisão de 79,50%. Após uma análise de sensibilidade, apenas oito dos 17 recursos mostraram relevância, reduzindo o tempo de treinamento de 11,49 para 7,908 minutos. O modelo robusto baseado em IA foi introduzido para prever falhas em três categorias, utilizando menos recursos e requerendo um tempo de treinamento mais curto. Esse modelo pode prever a primeira ocorrência de falha nas classes 1, 2 e 3 após a compra do dispositivo médico, permitindo um planejamento abrangente e orçamentário para a manutenção. Esta abordagem organiza a manutenção antes mesmo do primeiro incidente de falha, o que é o principal objetivo da utilização da IA nesse cenário [22].

Para minimizar futuras falhas, a substituição dos dispositivos da classe 2 é priorizada, seguida pela classe 3. O artigo também propõe um plano de substituição com base em uma sequência de falhas e na idade dos dispositivos, e compara o papel do país na organização orçamentária e na redução de custos no gerenciamento de manutenção. A gestão estratégica, considerando a criticidade e o histórico de manutenção dos dispositivos usando IA, aprimora tanto a manutenção quanto os custos operacionais. Foi indicada a estratégia de substituição que deve ser implementada primeiro para a classe 2, seguida pela classe 3, dependendo da idade dos dispositivos e da probabilidade de falhas. Foram comparadas duas técnicas,

Aprendizado de Máquina (ML) e Aprendizado Profundo (DL), sendo que ML demonstrou melhor desempenho em precisão, *recall*, especificidade e pontuação F1. No entanto, DL tem a vantagem de um tempo de treinamento mais curto, apesar de uma precisão ligeiramente inferior [22].

Ao desenvolver e treinar um modelo, é importante realizar uma análise de sensibilidade sobre quais são os recursos mais significativos para especificação de um dispositivo médico [27]. Como mostrado na Figura 1, os principais tópicos a serem considerados são:



Figura 1. Análise de sensibilidade de um dispositivo médico-hospitalar. **Fonte.** Autoria própria.

(i) **Complexidade da manutenção:** caracteriza-se pelo grau de dificuldade em concluir a manutenção de um equipamento médico-hospitalar. Existem três categorias: baixa, média e alta complexidade. Equipamentos de baixa complexidade têm circuitos eletrônicos e/ou mecânicos simples, facilitando a manutenção, que não requer habilidades especializadas. Já os de média complexidade exigem pessoal com formação básica e treinamento apropriado para reparos mais complexos. Equipamentos de alta complexidade demandam técnicos altamente qualificados, muitas vezes com formação superior e treinamento especializado, inclusive em instituições internacionais.

(ii) **Modelo, data de compra, fabricante, prazo de garantia, suporte:** além dos aspectos mencionados anteriormente, a avaliação do desempenho de um dispositivo médico também depende de fatores cruciais, como modelo, fabricante, país de origem, marca, período de garantia e qualidade do suporte oferecido. Dois dispositivos médicos adquiridos na mesma

época podem apresentar variações significativas em seu desempenho, na qualidade dos resultados obtidos e em seu estado operacional. Essas discrepâncias estão diretamente ligadas à sua origem, ao fabricante responsável pela produção, ao modelo específico escolhido e à qualidade do suporte oferecido em casos de falhas e para orientações no manuseio adequado do equipamento. A origem do dispositivo, seja ele produzido em diferentes países ou por fabricantes distintos, pode influenciar diretamente na confiabilidade e na durabilidade do equipamento. Além disso, as características específicas do modelo, como tecnologia embarcada, materiais utilizados e métodos de fabricação, desempenham um papel crucial no seu funcionamento eficiente e preciso. Outro fator determinante é a qualidade do suporte oferecido pelo fabricante. Dispositivos médicos com suporte eficaz e rápido em casos de falhas, além de fornecer orientações claras sobre o seu correto manuseio, tendem a ter uma vida útil mais longa e a proporcionar resultados mais consistentes. Portanto, ao avaliar o desempenho de um dispositivo médico, é essencial considerar não apenas as características técnicas do equipamento, mas também sua origem, fabricante, modelo específico, período de garantia oferecido e a qualidade do suporte pós-venda disponibilizado pela empresa responsável. Todos esses elementos contribuem significativamente para a eficácia e a confiabilidade do dispositivo no ambiente clínico ou hospitalar.

(iii) **Tempo de inatividade:** quando um dispositivo médico se encontra em estado não funcional, ele entra em um período de inatividade até que as devidas correções sejam realizadas. Durante esse intervalo, a prestação do serviço é impactada, causando potenciais atrasos e interrupções nas atividades clínicas. Nesse cenário, o usuário é forçado a buscar uma unidade de substituição ou reserva para atender às necessidades temporárias, prejudicando o funcionamento da gestão hospitalar e a qualidade do atendimento ao paciente.

(iv) **Serviços alternativos (comodato e locação):** no modelo de comodato, em que os equipamentos são cedidos temporariamente, a responsabilidade pela manutenção pode recair sobre o fornecedor ou ficar sob responsabilidade do cliente, a depender do tipo de contrato firmado. Na modalidade de locação, em que os equipamentos são alugados por um período determinado, a responsabilidade pela manutenção pode ser compartilhada entre locador e locatário. Ao recorrer a esses serviços alternativos, as instituições de saúde conseguem assegurar a continuidade dos cuidados, garantindo que pacientes e amostras sejam atendidos mesmo diante de imprevistos relacionados a equipamentos médicos defeituosos. Os chamados serviços alternativos atuam na minimização de interrupções nos cuidados ao paciente, especialmente quando um terceiro ou prestador de saúde privado é envolvido para fornecer assistência.

(v) **Equipamentos reserva:** é um dispositivo médico empregado temporariamente para substituir outro que apresenta falha ou mau funcionamento, assegurando uma interrupção mínima nos serviços prestados. Essa substituição, muitas vezes chamada de plano de contingência, é prontamente acionada assim que a falha é detectada, sendo limitada aos dispositivos médicos críticos previamente designados, que podem pertencer tanto ao inventário interno do hospital quanto ao de instituições parceiras.

(vi) **Custo de manutenção (terceirizados):** refere-se ao custo total despendido para resolver problemas relacionados aos dispositivos médicos. Em determinadas situações, a manutenção interna não é suficiente, tornando necessário recorrer a prestadores de serviços externos, acarretando custos adicionais.

Atualmente, os principais *players* do mercado de manutenção de dispositivos médicos são *GE Healthcare* (Chicago, IL, EUA), *Siemens Healthineers* (Erlangen, Alemanha), *Koninklijke Philips N.V.* (Amsterdã, Holanda), *Medtronic* (Dublin, Irlanda) e *Fujifilm Holdings Corporation* (cidade de Minato, Japão), *Canon, Inc. Corporation* (Otagawa, Japão), Grupo *Agfa-Gevaert* (Mortsel, Bélgica), *Carestream* (Rochester, NY, EUA), *Drägerwerk AG & Co. KGaA* (Lübeck, Alemanha), *Hitachi Medical Corporation* (Tóquio, Japão), *Althea Group* (Milão, Itália), *Olympus Corporation* (cidade de Shinjuku, Japão), *B. Braun Melsungen AG* (Melsungen, Alemanha), *KARL STORZ GmbH & Co. KG* (Tuttlingen, Alemanha) e *Aramark Services, Inc.* (Filadélfia, PA, EUA) [22].

Todos os recursos citados apresentam abordagens distintas para a gestão de dispositivos médicos e planejamento orçamentário de manutenção. Ao incorporá-los em um modelo de IA, será possível realizar análises preditivas com base em dados históricos e em tempo real, identificando padrões e antecipando falhas em equipamentos médicos. Algoritmos avançados podem prever quando um dispositivo está propenso a quebrar ou precisar de manutenção, permitindo intervenções proativas antes que ocorram problemas graves. Além disso, a IA pode otimizar o uso de recursos, sugerindo estratégias de manutenção preventiva eficazes e economizando custos a longo prazo.

Outro benefício da aplicação da IA é a melhoria na gestão do inventário de dispositivos médicos. Ao envelhecerem, esses equipamentos acumulam um elevado número de falhas e levam a enfrentar custos de manutenção elevados, períodos prolongados de inatividade e, ao ultrapassarem sua vida útil, colocam em risco a segurança do paciente. Vários fatores, como idade, utilização, ambiente, manuseio pelo usuário, especificações, disponibilidade de peças de reposição e segurança, afetam a vida útil desses dispositivos médicos. A capacidade da IA de identificar padrões ocultos nos dados históricos desses dispositivos pode facilitar a tomada

de decisões, agilizando o processo de substituição. Um sistema inteligente pode analisar padrões de uso e demanda, auxiliando na previsão de necessidades futuras, evitando excesso ou falta de equipamentos e garantindo que os hospitais estejam sempre bem equipados para fornecer tratamentos adequados aos pacientes, e conseqüentemente, sem realizar gastos desnecessários.

A aplicação da Inteligência Artificial pode desempenhar também um papel fundamental na otimização das políticas de descarte desses dispositivos médicos, identificando de maneira eficiente e ecologicamente sustentável aqueles que alcançaram ou estão prestes a atingir o fim de sua vida útil. Em um contexto global onde a consciência ambiental é crucial, contribuir para práticas ecologicamente responsáveis é de suma importância.

Compreendendo esses padrões, a Inteligência Artificial pode automatizar e aprimorar os processos de manutenção dos equipamentos médico-hospitalares, reduzindo significativamente o tempo necessário de análise de dados, com pouca ou nenhuma intervenção humana. Além disso, a capacidade preditiva da IA permite que as instituições de saúde realizem a manutenção dos equipamentos com base em condições operacionais ideais, melhorando o desempenho da equipe e prolongando o ciclo de vida dos dispositivos. Essa abordagem não apenas economiza recursos, mas também garante um ambiente hospitalar mais seguro e eficiente para pacientes e profissionais de saúde.

É crucial ponderar sobre o papel da inteligência artificial no avanço dos sistemas de cuidados de saúde. O Fórum Econômico Mundial, em 2016, reconheceu o ecossistema aberto de IA como uma das 10 tecnologias emergentes mais significativas. À medida que as aplicações de IA se tornam cada vez mais valiosas em diversos setores, é incontestável sua relevância no campo da medicina e da saúde. Nesse contexto, a integração inteligente dessas tecnologias promete não apenas aprimorar a eficiência dos cuidados de saúde, mas também abrir portas para inovações que podem transformar positivamente a qualidade de vida e o tratamento médico [3].

2.2. DIFICULDADES NA GESTÃO DE PARQUES TECNOLÓGICOS E NA ANÁLISE DE DADOS

Os chamados Parques tecnológicos são espaços ou ambientes dedicados à pesquisa, desenvolvimento e implantação de novas tecnologias. Em instalações médicas, esses parques são projetados para promover a integração da tecnologia com as necessidades do ambiente

clínico, buscando a melhoria na prestação de cuidados com a saúde e impulsionando as inovações no setor [28]. Mas, como qualquer outra atividade que visa auxiliar a equipe médica corretamente, os equipamentos de parques tecnológicos devem apresentar confiabilidade, sendo de suma importância a garantia da segurança, qualidade e bom funcionamento desse sistema, logo, deve haver uma boa gestão de equipamentos médicos.

Os sistemas de gestão de equipamentos demandam uma cuidadosa avaliação de custos e produtividade, conforme mencionado anteriormente. Isso inclui a consideração da diminuição de riscos e a garantia da segurança dos pacientes, permeando todo o processo desde a aquisição dos equipamentos, sua utilização, manutenção, até o descarte seguro e sustentável, estruturando um planejamento abrangente.

Com o propósito de assegurar a eficiência operacional do equipamento, é imprescindível que a instituição de saúde planeje as atividades de manutenção de modo a não impactar o fluxo de pacientes, prevenindo eventos indesejados e a necessidade de repetição de exames. Uma falha nesse processo pode desencadear uma série de desdobramentos negativos, que vão desde diagnósticos equivocados e indicações inadequadas de tratamentos, até situações extremas, como a perda de vidas. Assim sendo, a gestão hospitalar deve ser rigorosa, visando garantir que as inovações promovam mudanças produtivas e lucrativas para todos os envolvidos e, ao mesmo tempo, assegurar a manutenção e melhoria da qualidade dos serviços de saúde [28].

A gestão de equipamentos pode ser definida como estratégias necessárias para garantir um controle de manutenção e equilíbrio financeiro, alcançando a satisfação do utilizador, a diminuição de custos e aumento da qualidade [29]. De forma mais detalhada, ao longo do processo de aquisição de um novo equipamento, realiza-se uma análise minuciosa das especificações técnicas e estruturais que devem ser atendidas pelo estabelecimento de saúde. Este processo envolve pesquisas de mercado para avaliar as ofertas disponíveis do sistema desejado. Além de examinar critérios como marca, preço, funcionalidades e qualidade do equipamento, é preciso também dedicar muita atenção aos serviços oferecidos pelo fabricante; isso abrange a avaliação de contratos de manutenção, garantias estendidas, custo das peças de reposição, bem como a disponibilidade de treinamento técnico e operacional.

Após a seleção do equipamento e a conclusão bem-sucedida do processo de aquisição, inicia-se a etapa de incorporação da tecnologia na instituição. Essa fase engloba não apenas a instalação física do equipamento, mas também a implementação dos programas de treinamento técnico e operacional destinados aos profissionais responsáveis por sua utilização. Todo esse processo visa garantir não apenas a eficácia técnica do novo

equipamento, mas também a capacitação adequada da equipe para otimizar sua operação e extrair todos os benefícios que a tecnologia pode oferecer à instituição de saúde.

Na fase de utilização do equipamento, é fundamental realizar planejamentos abrangentes quanto às manutenções preventivas, corretivas e preditivas, visando controlar potenciais falhas e erros, garantindo a operação contínua e eficiente. Além disso, medidas precisas devem ser implementadas para assegurar a calibração dos sistemas conforme os padrões estabelecidos pelas normas técnicas e/ou pelo fabricante. Os equipamentos, seus acessórios e componentes devem ser integrados a um inventário detalhado, o qual deve ser constantemente atualizado para identificação do estado de utilização e a localização de cada item. É crucial gerar relatórios e análises periódicas, avaliando a eficiência do equipamento, pois essa prática permite a implementação proativa de atualizações ou substituições quando necessário. Esse enfoque sistemático contribui para a manutenção de um parque tecnológico de saúde eficiente e atualizado. Por fim, ao determinar a necessidade de renovação ou alienação de um sistema, deve-se conduzir estudos para avaliar a viabilidade financeira e logística do descarte do equipamento [28].

As manutenções dos equipamentos, embora gerem custos para a instituição, desempenham um papel crucial na prevenção de mau funcionamento e na garantia da confiabilidade máxima. A entrega de um serviço de qualidade ao paciente não apenas fortalece a fidelização do cliente, mas também resulta em retornos financeiros positivos para a instituição. Por outro lado, a interrupção inesperada do funcionamento de um equipamento pode resultar na incapacidade da instituição de atender aos pacientes, devido à escassez de recursos, resultando em perdas financeiras significativas. Essa situação não apenas compromete a eficiência operacional, mas também pode ter impactos negativos na reputação da instituição e na satisfação dos pacientes. Portanto, a gestão eficaz das manutenções é essencial para evitar não só os custos imediatos associados à interrupção dos serviços, mas também potenciais repercussões a longo prazo.

Em um estudo realizado por Lopes [28], baseado em dados fornecidos por uma empresa de equipamentos médicos de diagnóstico por imagem, pelo período de 01 de outubro de 2017 a 30 de setembro de 2018, foram coletados dados sobre manutenções corretivas e a base de equipamentos ativos no Brasil. As modalidades de equipamentos analisadas foram: equipamentos de radiodiagnóstico, com foco em equipamentos de Raios X, Mamografia, Tomografia Computadorizada e Terapias Avançadas (Angiografia e Arco Cirúrgico). A base de ocorrências de manutenções corretivas inclui informações como número de rastreabilidade, datas de início e fim da manutenção, modelo e número de série, região de alocação, descrição

do problema e estado da máquina no início da ocorrência. A base de equipamentos ativos, chamada de 'base instalada', foi extraída em 21 de novembro de 2018, contendo informações detalhadas para cada equipamento, como modelo, lote, datas de finalização pela fábrica e entrega ao cliente, localização e situação de contratos de manutenção. Devido à falta de informações sobre gestão e manutenção de equipamentos sem contratos, o estudo foi restrito aos equipamentos com contratos ativos. Na planilha da base instalada, uma busca foi realizada para identificar equipamentos com contratos de manutenção ativos, e esses números foram comparados com os números de equipamentos na base de ocorrências de manutenção corretiva. Os modelos dos equipamentos foram classificados consoante a modalidade de radiodiagnóstico (MM - Mamografia, RX - Raios X, AX - Terapias Avançadas e CT - Tomografia Computadorizada) seguindo um padrão estabelecido pela empresa, facilitando análises por modalidades em todas as ocorrências de manutenção corretiva [28].

Os resultados provenientes da análise dos dados fornecidos pela empresa revelam que ao longo do período analisado foram registrados 12.330 chamados de manutenção corretiva, com uma média mensal de 1.028 ocorrências. Agosto de 2018 destacou-se como o mês com o maior número de ocorrências, totalizando 1.258 chamados, enquanto dezembro de 2017 registrou a menor quantidade, possivelmente influenciado pelo período de festas de final de ano e feriados. A modalidade de Tomografia Computadorizada (CT) liderou em número absoluto de ocorrências, totalizando 5.233 chamados, representando quase metade do total. Além disso, apresentou a maior média mensal de chamados, alcançando 436 ocorrências por mês. Equipamentos de Angiografia e Arco Cirúrgico, pertencentes à categoria de Terapias Avançadas (AX), ficaram em segundo lugar em número absoluto de incidências, com uma média mensal de 307 ocorrências. Em terceiro lugar, os Raios X (RX) registraram 2.284 chamados ao longo do ano, com uma média mensal de 190 ocorrências. Por fim, a modalidade de Mamografia (MM) apresentou a menor quantidade de chamados, totalizando 1.134 ocorrências e uma média de 95 incidências por mês [28].

Dada a expectativa de que um grande volume de equipamentos resultaria em mais chamados de manutenção em comparação com um volume menor uma correlação entre os dados de manutenção corretiva e as informações da base instalada foi realizada a fim de verificar as proporções entre a quantidade de equipamentos e a quantidade de manutenções corretivas, avaliando a significância desses números de ocorrências. Esta proporção foi denominada como 'Quantidade de Manutenções Corretivas por Equipamento Ativo', representando o número médio de manutenções corretivas para um equipamento ativo por modalidade.

A modalidade MM, apesar de ter o menor número de equipamentos e o menor número de ocorrências, apresentou uma incidência baixa de chamados de manutenção. Por outro lado, a CT, apesar de possuir a segunda menor base instalada, registrou o maior número de chamados de manutenção corretiva. As modalidades RX e AX seguem a lógica esperada em termos proporcionais, pois possuem o número de equipamentos ativos e de manutenções corretivas equilibradas. A média geral de chamados de manutenção corretiva por equipamentos para todas as modalidades foi de 2,9, e observa-se que todas as modalidades radiológicas, exceto a tomografia computadorizada (CT), tiveram uma média de ocorrências de manutenção corretiva menor que a média geral de todos os equipamentos. Isso indica que os equipamentos dessas modalidades tiveram uma incidência de problemas inferior à média de todas as modalidades estudadas. A menor média de chamados por equipamento ativo foi observada nos equipamentos de RX, com uma média de 1,8 incidências, seguida por mamografia (MM) e terapias avançadas (AX), com médias de 2,1 e 2,2, respectivamente. Por outro lado, a CT apresentou uma média de ocorrência 2,2 vezes maior que a média geral, indicando que cada equipamento ativo teve uma média de 6,3 ocorrências de manutenção corretiva ao longo do período analisado [28].

Além de analisar a correlação entre o número de chamados de manutenção corretiva e o número de equipamentos ativos na base instalada, investigou-se também a quantidade de equipamentos que enfrentaram problemas ao longo do período em estudo. Observou-se que expressivos 84,7% de todos os equipamentos de tomografia computadorizada desta empresa apresentaram problemas, indicando que apenas 15,3% dos equipamentos não registraram nenhum tipo de ocorrência. Em termos absolutos, dos 826 equipamentos de tomografia computadorizada distribuídos pelo Brasil, 700 enfrentaram algum tipo de problema durante o ano, enquanto 126 equipamentos estiveram isentos de ocorrências.

Para as outras modalidades, o cenário foi menos desafiador, com porcentagens de 59%, 57,8% e 48,3% para as terapias avançadas (AX), mamografia (MM) e raios X (RX), respectivamente. A modalidade AX se destaca pelo maior número absoluto de equipamentos que enfrentaram problemas, totalizando 975 equipamentos. No entanto, essa modalidade também possui a maior quantidade de equipamentos na base instalada, o que, em proporções, não é tão significativo quanto na modalidade CT. A modalidade RX foi a única em que menos da metade dos equipamentos tiveram alguma ocorrência de manutenção, sendo 629 equipamentos de 1301. Moraes et. al supôs que o número de ocorrências de manutenção corretiva também pode estar relacionado à complexidade da modalidade, visto que RX é menos complexo que CT. Diante do destaque da modalidade CT em todas as análises

anteriores, com uma das menores quantidades de equipamentos na base instalada, o maior índice de manutenção corretiva e uma alta porcentagem de equipamentos ativos que apresentaram problemas, a autora optou por um estudo mais aprofundado dessa modalidade radiológica [28].

Na análise da modalidade de tomografia computadorizada, 42% das ocorrências de manutenções corretivas ocorreram em condições operacionais normais, sugerindo que essas situações podem estar relacionadas a dúvidas pontuais sobre o equipamento e/ou pequenos ajustes, sem necessariamente representar problemas que restrinjam o uso do equipamento. Em contrapartida, 58% dos problemas enfrentados resultaram em alguma limitação de uso, incluindo 22% onde a máquina ficou completamente parada. Embora a porcentagem de máquinas paradas seja a menor entre os *status* apresentados, os números absolutos ainda são significativos, com 1161 chamados de manutenção corretiva registrando a máquina parada em meio às 5225 ocorrências totais.

Considerando os resultados gerais da modalidade de tomografia computadorizada, foram conduzidos estudos específicos para cada modelo de equipamento, visando comparar o desempenho entre eles e identificar possíveis padrões de manutenção associados às características específicas de cada modelo. Visando identificar possíveis padrões e comparar os modelos entre si, conduziu-se uma análise utilizando o Indicador de Ocorrência de Manutenção Corretiva (IOMC), que representa a influência da idade e do tamanho da base instalada do modelo nas incidências de manutenções corretivas.

Essa métrica foi elaborada considerando a premissa de que equipamentos mais antigos têm maior probabilidade de apresentar problemas devido ao desgaste e à tecnologia menos avançada. Também foi considerado que modelos com mais equipamentos têm uma probabilidade maior de gerar chamados de manutenção corretiva. Dessa forma, esperou-se que modelos mais antigos apresentassem mais ocorrências de manutenção corretiva. Destacaram-se quatro modelos por serem relativamente novos, com até 7 anos, que exibiram um número elevado de problemas. Em contrapartida, um modelo com uma média de idade mais avançada, 9,9 anos, e uma base instalada reduzida, totalizando 19 equipamentos, ilustrou a situação de poucos equipamentos que enfrentaram muitos problemas, um cenário mais previsível considerando que são equipamentos mais antigos [28].

O estudo em foco abrange uma extensa gama de dados, e vale ressaltar que sua análise foi restrita a apenas algumas modalidades de equipamentos médico-hospitalares de uma determinada empresa. Pensando no parque tecnológico total, a análise de todos esses dados pode acabar se tornando um problema devido à complexidade do contexto organizacional e

pelas inúmeras variáveis a serem consideradas. Esta limitação reflete a necessidade de um sistema inteligente e transparente para a análise abrangente de todas as modalidades, com o propósito de avaliar as informações de manutenções e caracterizar problemas recorrentes em cada modelo de equipamento a fim de reduzir riscos e melhorar a segurança.

3. DISCUSSÕES

3.1. COMO A INTELIGÊNCIA ARTIFICIAL PODE SER APLICADA PARA AUXILIAR NA GESTÃO DE EQUIPAMENTOS MÉDICOS

A priorização de dispositivos médicos tem sido uma questão muito importante para as organizações de saúde há anos. No presente estudo, a principal abordagem é a aplicação da Inteligência Artificial como principal ferramenta de auxílio à gestão desses dispositivos.

A tomada de decisões clínicas com o uso da Inteligência Artificial envolve diversas abordagens e técnicas, tais como Aprendizado de Máquina (ML), Aprendizado Profundo (DL) e robótica. Esse procedimento engloba a coleta e interpretação de dados pertinentes, neste caso, provenientes de equipamentos médico-hospitalares. A IA, por sua vez, oferece sugestões para que sejam tomadas ações mais apropriadas, visando melhorar ou manter a qualidade e segurança do funcionamento do dispositivo. Em outras palavras, o sistema precisa assimilar o contexto do problema, baseando-se principalmente em probabilidade e estatísticas, para gerar resultados eficazes. A qualidade dos dados fornecidos é de importância crucial, visto que, inicialmente, esses algoritmos são frágeis e inconsistentes. Entretanto, à medida que executam tarefas específicas de forma repetitiva, ganham robustez e confiabilidade.

Ao abordar a tomada de decisões computacionais no setor de saúde, é necessário considerar não apenas a detecção ou previsão de doenças, a biomedicina e a análise de imagens biomédicas, mas também aspectos cruciais como pesquisa de tratamentos médicos, atendimento ao paciente, alocação de recursos, gestão do volume hospitalar, formulação de políticas de saúde e outros desafios. Tendo como exemplo a situação desencadeada pela pandemia de COVID-19, tornou-se evidente que todos os pontos mencionados necessitam de atenção no âmbito da saúde, e tais tarefas devem ser realizadas em prazos consideravelmente curtos. Diante desse cenário, a abordagem mais eficaz consiste em utilizar a tomada de decisão computacional baseada em aprendizado de máquina no setor de saúde, especialmente em momentos tão críticos. Essa é a razão pela qual observamos uma crescente demanda por "aprendizado de máquina de emergência" no cenário global atual [19].

Os algoritmos em Inteligência Artificial possuem a capacidade de executar análises preditivas ao filtrar, ordenar e pesquisar padrões em grandes conjuntos de dados de diversas fontes para fornecer decisões rápidas e de qualidade. Essas informações coletadas de um conjunto de dados são chamadas de recursos, e a precisão da análise da IA depende essencialmente da qualidade dos recursos fornecidos.

3.1.1. *Aprendizado de máquina*: Para desenvolver um sistema que melhor se adeque ao propósito de predição de manutenção de equipamentos médico-hospitalares, é dever do desenvolvedor identificar qual o melhor subconjunto de recursos que se adequa ao objetivo, aumentando a precisão do modelo. Ao considerar a implementação do Aprendizado de Máquina, é essencial percorrer três etapas: treinamento, teste e validação. A etapa de treinamento assume relevância crucial, pois a precisão dos resultados está intrinsecamente ligada ao conjunto de dados utilizado. Posteriormente, por meio de um conjunto de dados de teste, avalia-se o desempenho do algoritmo. A utilização desses mesmos dados para aferir o desempenho é importante para diminuir o viés e aumentar a variância durante a fase de testes, pois um algoritmo de aprendizado de máquina eficiente busca otimizar a relação entre viés e variância. A avaliação final do desempenho do algoritmo é conduzida com base no conjunto de dados de validação durante o período de validação. Este processo abrangente, compreendendo treinamento, teste e validação, é crucial para assegurar a robustez e a generalização do modelo de aprendizado de máquina [19].

3.1.2. *Aprendizagem supervisionada*: que se concentra tanto na classificação, envolvendo a seleção entre subgrupos para descrever de forma mais precisa uma nova instância de dados, quanto na previsão, que implica na estimativa de um parâmetro desconhecido. Este método é frequentemente empregado para a estimativa e modelagem de riscos, identificando relações que podem não ser prontamente perceptíveis aos olhos humanos [19].

3.1.3. *Árvores de Decisão*: DT é um algoritmo supervisionado que utiliza um modelo em formato de árvore, onde as decisões, possíveis consequências e seus resultados são cuidadosamente considerados. Em cada nó da árvore, uma pergunta é formulada, cada ramo representa um possível resultado, e as folhas contêm os rótulos de classe [19]. Apesar da facilidade de compreensão desse algoritmo, ele apresenta alguns problemas, como o de *overfitting*, no qual o modelo se ajusta excessivamente aos dados de treinamento e pode ter um desempenho inferior em novos dados. Além disso, ao lidar com conjuntos de dados desequilibrados, pode haver uma tendência do algoritmo em direção aos resultados mais representativos, prejudicando a generalização para classes minoritárias.

3.1.4. *Algoritmo de Floresta Aleatória*: RFA é uma tendência técnica no campo do aprendizado de máquina capaz de realizar tarefas de regressão e classificação. Trata-se de um algoritmo supervisionado, cuja metodologia básica é baseada na recursão. No RFA, um conjunto de árvores de decisão é criado, e o método de *bagging* (técnica de *ensemble learning* usada para melhorar a estabilidade e a precisão de algoritmos de aprendizado de máquina) é

utilizado para fins de treinamento. [19] Uma característica distintiva do RFA é a sua insensibilidade ao ruído, tornando-o eficaz para lidar com conjuntos de dados desequilibrados. Além disso, o problema de *overfitting* não é proeminente no RFA, conferindo robustez ao modelo. Essas características fazem do RFA uma ferramenta valiosa em aplicações que demandam precisão e generalização, especialmente em cenários desafiadores, como é o caso da manutenção de equipamentos mais robustos.

3.1.5. *Rede Neural Artificial*: A Rede Neural Artificial (ANN) é uma abordagem supervisionada de Aprendizado de Máquina amplamente reconhecida por sua eficácia em problemas de classificação de imagens. No contexto do Aprendizado de Máquina, os neurônios artificiais formam o conceito básico da ANN, que se assemelha às redes neurais biológicas. Uma ANN típica possui três camadas onde cada nó em cada camada está conectado a todos os nós nas outras camadas e a profundidade da rede neural pode ser aumentada ao adicionar mais camadas ocultas. Dentro das redes neurais, três tipos de funções desempenham papéis cruciais. A função de erro avalia quão precisa foi a saída para um determinado conjunto de entradas, a função de otimização identifica ajustes que podem reduzir a função de erro, e, por fim, a função de atualização determina como as mudanças devem ser implementadas com base na função de otimização. Esse é um processo iterativo, no qual a performance do algoritmo melhora à medida que a rede neural é ajustada ao longo do tempo [19].

Quando discutimos a aplicação da Inteligência Artificial na área da Saúde, é evidente que ela desempenha um papel crucial também em diagnósticos e tratamentos, como mencionado repetidamente neste documento, através dos métodos citados anteriormente e outros adicionais, entre os quais se destaca a Aprendizagem Não Supervisionada.

A Aprendizagem Não Supervisionada é quando o desenvolvedor não possui uma compreensão prévia clara dos dados envolvidos no sistema, tornando inviável rotular os mesmos para formar um conjunto de dados de treinamento. Nesse cenário, os algoritmos do sistema são empregados para identificar padrões, semelhanças e diferenças entre os objetos de dados. Por exemplo, durante o diagnóstico de uma doença específica em um paciente, o algoritmo pode identificar outras condições presentes no organismo, aprendendo autonomamente a considerar fatores relevantes para diversos tipos de doenças. Além disso, ao contrário de abordagens tradicionais que podem exigir a análise de diferentes conjuntos de dados em separado, a Aprendizagem Não Supervisionada permite a análise simultânea de diversos dados. Essa abordagem não só oferece eficiência, mas também otimiza significativamente o tempo, resultando em uma avaliação mais abrangente e sucinta [19].

A aplicação destes métodos também pode resultar em avanços significativos na área de manutenção preditiva. A abordagem do Aprendizado Não Supervisionado tem o potencial de antecipar falhas em dispositivos ao analisar ocorrências semelhantes em modelos comparáveis, uma vez que nenhum dado rotulado é fornecido ao sistema para previsões. Essa abordagem busca identificar padrões ou agrupamentos que ocorrem naturalmente, sendo o desafio determinar se esses grupos ou padrões são úteis. Ao cruzar informações provenientes de equipamentos médico-hospitalares, a tomada de decisões na área da saúde seria ainda mais aprimorada, resultando em uma gestão mais eficaz e proativa na manutenção de dispositivos críticos. Esse enfoque não apenas promove a identificação antecipada de possíveis falhas, mas também proporciona uma compreensão mais profunda dos padrões emergentes nos dados, contribuindo para decisões informadas e eficazes no ambiente hospitalar.

3.1.6. *Clustering*: uma abordagem de aprendizado não supervisionado utilizada para agrupar entradas em clusters, os quais não são identificados previamente, mas são organizados com base em semelhanças. No contexto do clustering, as abordagens principais são divididas de acordo com características distintas, como particionamento (k-means), hierarquia, baseado em grade, baseado em densidade ou baseado em modelos. Além disso, essas categorias podem ser subdivididas com base em tipos de dados, como numéricos, discretos e mistos. As relações de herança entre algoritmos de clustering dentro de uma abordagem evidenciam recursos e melhorias comuns que se complementam. Velocidade, parâmetros mínimos, sensibilidade à ruído, tratamento de valores discrepantes, manipulação de redundância e capacidade de lidar com objetos independentes de ordem são características desejadas em algoritmos de clustering destinados à implementação em aplicações biomédicas. Esses algoritmos são particularmente úteis quando os conjuntos de dados são grandes e complexos demais para serem analisados manualmente, proporcionando uma maneira eficaz de extrair informações significativas de dados biomédicos densos e extensos [19].

3.1.7. *Aprendizagem Semi Supervisionada*: nesta abordagem, é fornecido um conjunto parcial de dados de treinamento. Esse tipo de treinamento é usado quando alguns resultados ausentes podem ser alvo de alguns dados de treinamento. Os algoritmos de aprendizado semi-supervisionado são treinados utilizando dados rotulados e não rotulados, e, devido a essa combinação, esses algoritmos exibem características tanto dos algoritmos de aprendizado de máquina supervisionados quanto dos não supervisionados [19]. Essa abordagem permite explorar a interseção entre dados rotulados e não rotulados, ampliando as possibilidades de treinamento e melhorando a generalização do modelo em cenários em que os rótulos podem ser escassos ou difíceis de obter.

3.1.8. *Aprendizado Profundo*: Trata-se de uma fase avançada de Aprendizado de Máquina que se desenvolve em torno de redes neurais para aprender e prever dados. Ao adotar essa abordagem, torna-se possível implementar sistemas mais complexos e generalizados capazes de lidar com uma variedade ampla de problemas, fornecendo previsões precisas em relação a cada um deles.

3.1.9. *Aprendizado Ativo*: nesse sistema, as *tags* de treinamento são adquiridas apenas para um conjunto restrito de ocorrências. A otimização é então aprimorada, buscando ganhar *tags* para os objetivos específicos. Uma vantagem dessa abordagem é que o algoritmo não apenas aprende de maneira contínua, mas também adquire conhecimento de forma autônoma, sendo posteriormente validado por meio de consultas interativas a um usuário ou a uma fonte de informação. Isso resulta em um processo interativo e adaptativo, onde o sistema não apenas se aprimora continuamente, mas também incorpora informações importantes que foram validadas e enriquecidas por interações à fontes de dados adicionais [19].

Os computadores possuem a capacidade única de executar tarefas de maneira consistente e incansável. Nos últimos anos, o Aprendizado de Máquina tem demonstrado sua habilidade em aprender e dominar atividades previamente consideradas complexas demais para máquinas, muitas vezes identificando padrões além da percepção humana. Porém, vale salientar que fazer uma distinção exata de qual o melhor algoritmo não é uma tarefa simples, pois isso depende de uma série de variáveis. Dentre as quais incluem o domínio específico do treinamento e dos testes, a natureza do conjunto de dados utilizado, os procedimentos de pré-processamento aplicados, os recursos escolhidos para o algoritmo, a utilização de algoritmos de seleção de recursos, o tamanho do conjunto de dados, a tipologia dos dados envolvidos, o desempenho e a capacidade da máquina, entre outros fatores. Dessa forma, a escolha minuciosa do algoritmo mais adequado para cada tarefa é crucial. Geralmente, esse processo não se dá por uma seleção direta, mas sim por meio de iterações, demandando conhecimento sólido e experiências passadas. A construção de um conjunto filtrado de algoritmos requer uma abordagem cuidadosa, fundamentada em insights e práticas anteriores, o que é essencial para alcançar resultados eficazes e otimizados.

4. FUTURO

4.1. XAI

Acompanhando o avanço da Inteligência Artificial e suas potenciais aplicações na saúde, a explicabilidade (XAI) se tornou um dos tópicos mais debatidos por invocar questões médicas, legais, éticas e sociais, ou seja, questões que vão além do âmbito puramente tecnológico. A literatura sobre Inteligência Artificial Explicável (XAI) é vasta e interdisciplinar, e além de estar em constante expansão, há uma discussão vívida sobre a utilidade e necessidade de XAI na medicina [30], mas o objetivo que a descreve é o mesmo: satisfazer interesses, objetivos, expectativas, necessidades e demandas relacionadas a sistemas de Inteligência Artificial (IA) inteligíveis para as partes humanas interessadas, permitindo entender por que razões um modelo caixa preta produziu um resultado específico em uma variedade de contextos.

A IA Explicável (XAI) é um domínio de técnicas desenvolvidas para explicar decisões feitas por sistemas de IA, de modo a apresentá-las com transparência, rastreamento de resultado, e, conseqüentemente, maior confiabilidade. As aplicações de IA na saúde remetem a um sistema de saúde eficiente, conveniente e personalizado. A proliferação de fluxos de trabalhos digitalizados cruzou com o aumento dramático nos recursos de Aprendizado de Máquina (ML), e acabou gerando muitas preocupações éticas e regulatórias por parte do corpo clínico, o que é relevante em questões como confiabilidade e vulnerabilidade, pois quando os fatores de tomada de decisão, as limitações e as fontes de viés dos sistemas baseados em ML são opacos ou pouco claros, sua aplicação nos contextos de diagnóstico e tratamentos é significativamente restrita [31]. Nesse contexto, a XAI surge como um meio de promover a aceitação de soluções de IA por seus usuários-alvo, trazendo melhores resultados para os pacientes e redução da carga de trabalho do médico por meio da automação de tarefas repetitivas, revelando como uma decisão de IA é formada e pode ser usada para entender e confiar adequadamente no resultado dado pela máquina.

No cenário tratado no presente estudo, a XAI emerge como um elemento crucial, promovendo não apenas uma confiabilidade ampliada na predição da manutenção de equipamentos, mas também proporcionando uma rastreabilidade mais aprimorada quanto ao tratamento dos dados pelo sistema inteligente.

Contudo, apesar de serem inúmeros os benefícios, também são inúmeros os desafios encontrados, dentre eles a discussão em torno da questão ética apresenta-se com grande

relevância. Incertezas legais e éticas podem impedir o progresso do papel da explicabilidade na IA médica e causar consideráveis danos. Para explorar plenamente as possibilidades e obter o máximo de proveito, as questões de privacidade, segurança de dados, responsabilidade, e claro, o também indispensável “fator humano” precisam ser amplamente considerados. Muito se fala sobre as implicações ético-jurídicas, sobre quais os limites dos sistemas inteligentes, os riscos para os direitos humanos, porém há uma carência de estudos acerca da utilização da XAI na resolução desses desafios entre as necessidades de inovação e regulamentação, aspecto que merece uma análise cuidadosa.

4.2. DESAFIOS

Embora a Inteligência Artificial seja uma tecnologia emergente que demonstra crescente capacidade de auxiliar em atividades humanas cruciais, há diversos desafios a serem superados. Especificamente, no contexto do suporte à predição da manutenção de dispositivos médicos, encontramos com obstáculos como variados julgamentos, possíveis censuras de dados por parte dos fabricantes, a falta de total confiança por parte de alguns especialistas em suas próprias opiniões, informações não devidamente expressas, entre outros. Esses elementos acabam dificultando a abordagem do problema, aumentando o risco de o modelo não ter muita lógica e transparência. Além disso, destacam-se outros pontos relevantes, como:

4.3.1. *Nível de confiança no sistema*: não entender como e por quê um sistema de IA toma uma decisão pode levar à desconfiança e à falta de confiança, mesmo que este seja muito preciso. Por outro lado, confiar demais em um sistema de IA com falha pode levar a resultados devastadores em decisões de alto risco [30]. De maneira geral, os sistemas baseados em IA tem se popularizado, estando cada vez presentes no cotidiano de pessoas, de empresas, em sistemas de reconhecimento facial, drones inteligentes, câmeras de segurança, uso militar voltado ao campo da espionagem, entre outros, são apenas alguns exemplos da utilização do novo avanço tecnológico baseado no mapeamento da forma cognitiva dos seres humanos. Por conta disso, as decisões têm sofrido um intenso processo de automatização baseada em critérios na maioria das vezes não conhecidos ou bem explicados por seus criadores, de modo que passam a ter grande influência no dia a dia das pessoas sem que elas necessariamente percebam [32].

No caso de incredulidade, ocorre a possibilidade de tentativa por parte dos usuários de supervisionar constantemente o comportamento do sistema ou tentar intervir nos processos do mesmo, prejudicando assim a eficácia da interação humana com o sistema. Dessa maneira,

quando aplicada na saúde, é crucial que haja um alto nível de confiança e compreensão, para satisfazer as necessidades legais e regulatórias, garantindo responsabilidade social, entre outros aspectos. Assim, tornou-se uma exigência legal que todos os softwares usados como dispositivos médicos exibam um nível adequado de transparência.

Todo esse cenário de incerteza gera uma grande desconfiança no corpo clínico, pois no âmbito da saúde, é imprescindível que tudo relacionado ao paciente seja seguro e processado de maneira sensível. Assim, um sistema de IA com a finalidade específica de predição de manutenção de dispositivos, é suscetível de materializar um risco elevado, em caso de não serem cumpridos os requisitos legais, à documentação e à manutenção de registros, à transparência e à prestação de informações aos utilizadores, à supervisão humana, à solidez, à exatidão e à segurança. Por outro lado, principalmente após a pandemia, ocorreu um grande avanço da telemedicina, e seguimos assistindo à uma autonomização progressiva das áreas de suporte dos hospitais, libertando o hospital para as suas funções nucleares: assistência, ensino e investigação.

Essa transformação digital oferece diversas vantagens e acaba por democratizar o acesso da população a um atendimento à saúde de qualidade. Mas, por mais sofisticado que seja, um sistema de IA não está isento de produzir resultados imprecisos, incompletos ou tendenciosos. Várias razões podem estar por trás de um resultado preditivo errôneo, como: dados de entrada podem ser inacabados ou conflitantes entre si, gerando ambiguidades para o algoritmo que os analisa; a predição computacional pode estar mal calibrada ou insuficientemente treinada, falhando na interpretação desses dados e terminando por fornecer resultados incorretos; há ainda os casos em que o algoritmo “acerta” a resposta, lançando mão, no entanto, de raciocínios e aproximações não desejáveis. A falibilidade ocorre quando um sistema fracassa ao correlacionar os dados de modo causal, gerando evidências inconclusivas e ações injustificadas [33].

4.3.2. *Desafios jurídicos*: atualmente, é muito rara a atividade humana que para ser executada não necessita de algum tipo de tecnologia que obtém e cria dados, deixando rastros que funcionam posteriormente como combustível das IAs de processamento de dados, denominadas *big data*. Apesar dos benefícios significativos associados a essas aplicações, é crucial reconhecer os inerentes riscos e perigos. Diante desse cenário, torna-se imperativo adotar uma abordagem jurídica abrangente para estabelecer regulamentações adequadas, a fim de prevenir potenciais prejuízos a fabricantes, gestores hospitalares e governos. O envolvimento de departamentos jurídicos viabiliza que o corpo clínico exponha suas inseguranças e que os fabricantes de equipamentos e desenvolvedores de modelos inteligentes

investiguem em seus modelos todas as possíveis vulnerabilidades, trabalhando sempre em colaboração com todos os atores envolvidos, como engenheiros da computação, profissionais de saúde e pacientes.

4.3.3. *Desafios éticos*: uma série de desafios têm dificultado o progresso da IA na saúde, desde as barreiras de compartilhamento de dados específicos de saúde até o desenvolvimento, adoção e implementação de sistemas de IA em fluxos de trabalho de atendimento clínico de forma eficaz e transparente. Quando utilizamos a tecnologia para suporte em saúde, precisamos, inicialmente, questionar se essas ferramentas serão úteis em relação aos possíveis resultados obtidos, mostrando qual é o nível de confiança diante dos dados obtidos, se a decisão obtida é clinicamente aceitável e/ou se possui alto índice de sucesso [34]. No entanto, para todas essas questões, necessitamos atentar para as reflexões éticas e bioéticas inerentes aos questionamentos. As novas potencialidades da bioética desafiam também o próprio controle da tecnologia.

A transparência necessária no tratamento dos dados, no geral, torna-se opaca, na medida em que o uso de sistema do Aprendizado de Máquina (ML), em que as máquinas aprendem e se ajustam sozinhas, faz com que a auditabilidade seja limitada. É essencial que os conjuntos de dados e processos utilizados na construção de sistemas de IA sejam documentados e rastreáveis, e que sejam dotados da XAI, para que as respostas fornecidas pela IA possam ser compreendidas, facilitando uma avaliação contínua dos conflitos éticos. Quando aplicada na saúde, a IA tem um problema de ganho: tal como uma peça defeituosa em uma linha de montagem, a IA multiplicará, não centenas, mas milhares de vezes seus erros [35].

As novas tecnologias demandam limites e responsabilidades, e, portanto, diretrizes éticas que enfrentam as várias perspectivas, e promovem um equilíbrio na relação de riscos e benefícios decorrentes do uso da IA na área da saúde. A tomada de decisão ética é entendida como uma conclusão obtida a partir de limites, princípios, valores e normas sociais que desempenham um papel central na determinação de quais atitudes e/ou respostas comportamentais são aceitáveis para uma situação problema. Muitas decisões éticas exigem a seleção de uma ação quando as informações estão incompletas ou confusas, e um possível resultado pode não ser previsto ou possuir um grau de confiabilidade aceitável, já que valores conflitantes podem dificultar o processo de tomada de decisão [36].

4.3.4. *Cinco classes de riscos envolvendo IA*: Thomas Dietterich e Eric Horvitz [37] elencaram cinco classes de riscos envolvendo o uso de sistemas de IA:

- **falhas (*bugs*)**: todos os sistemas de *software* estão sujeitos a falhas. Muitos sistemas de software convencionais foram meticulosamente desenvolvidos e validados para garantir

elevados padrões de qualidade. Da mesma forma, é crucial aplicar práticas semelhantes no desenvolvimento de sistemas de Inteligência Artificial;

- **segurança (*cybersecurity*):** os sistemas de IA compartilham a mesma vulnerabilidade que outros *softwares* em relação a ataques cibernéticos. Diante da crescente complexidade e interconexão desses sistemas avançados, é imperativo que sejam adotadas medidas robustas de segurança para mitigar riscos potenciais;

- **aprendiz de feiticeiro (*sorcerer's apprentice*):** um elemento crucial em qualquer sistema de IA que interage com indivíduos é a capacidade de interpretar e compreender as intenções das pessoas, em vez de simplesmente executar comandos de maneira literal;

- **autonomia compartilhada (*shared autonomy*):** a criação de sistemas em tempo real, nos quais o controle necessita transitar rapidamente entre os seres humanos e as Inteligências Artificiais, é uma tarefa complexa devido à necessidade de sincronização precisa e entendimento contínuo das intenções e metas envolvidas;

- **impactos socioeconômicos:** é fundamental aprofundarmos nossa compreensão sobre como a Inteligência Artificial impacta a distribuição de empregos e a economia em uma perspectiva mais abrangente. Essas questões transcendem os campos da ciência, alcançando o domínio das políticas e programas econômicos a fim de que sejam desenvolvidas estratégias que assegurem que os benefícios decorrentes dos avanços de produtividade baseados em IA sejam equitativamente compartilhados, promovendo assim uma transformação positiva e inclusiva em diversos setores.

Dentre estes riscos, quando aplicados na saúde, o primeiro, segundo e quarto tópico merecem maior atenção. Ao lidar com vidas, é imprescindível que a tecnologia utilizada esteja sempre em perfeitas condições de utilização, os riscos de falhas devem ser minuciosamente analisados, solucionados e evitados; por fim, a autonomia compartilhada, ou seja, o trabalho em conjunto com o engenheiro clínico, o fabricante, o gestor hospitalar, o médico, com o paciente, seguindo a premissa a qual foi designada, de apoio à decisão clínica, sempre de maneira transparente e que possa ser compreendida por todos.

4.3.5. *Entendimento das partes interessadas:* para explicar um resultado, têm-se que determinar o grau apropriado e o tipo de entendimento sobre o sistema e sua saída para que haja entendimento satisfatório de todas as partes que irão trabalhar com aquela informação. Isso significa que é necessário avaliar o grau real e o tipo de compreensão das partes interessadas, ao ponto que estas consigam entender o funcionamento do sistema e assimilar o resultado fornecido por ele. O próximo passo no cenário de descoberta é definir quais informações explicativas têm o potencial de facilitar o tipo e o grau corretos de compreensão

em um contexto pré determinado. Para que isso ocorra, deve ser feita uma avaliação de diferentes dimensões da informação explicativa em relação aos efeitos esperados dentro de um processo de explicação. São pontos de atenção, por exemplo: o tipo de informação, seu formato de apresentação, sua qualidade, sua quantidade, sua completude, sua complexidade ou sua adequação a determinado contexto [31].

Sob qualquer perspectiva, é inegável que a IA alcançou um tremendo sucesso. Porém, não devem ser marginalizados os problemas e desafios que são acarretados por essa constante evolução. Levantar questões éticas fundamentais sobre o impacto da IA no trabalho, nas interações sociais, na justiça, na segurança, e como relatado no presente documento, nos cuidados de saúde, é de suma importância para que o sistema de classificação de máquina não se baseie e se desenvolva sob violações aos direitos da sociedade e, como se tem visto, perpetuando erros humanos, como o preconceito. Pesquisadores, engenheiros, médicos, pacientes, políticos, devem reconhecer os benefícios das tecnologias de IA, e fazer prevalecer o seu uso seguro, benéfico e justo.

4.3. PERSPECTIVAS

Conforme destacado no relatório de pesquisa da *The Business Research Company* (empresa *Business Research*, 2020), o mercado global de dispositivos médicos está experimentando um crescimento notável. Esse crescimento é atribuído ao aumento dos casos de doenças infecciosas e crônicas, à expansão do número de instalações de saúde, ao aumento das despesas com saúde, aos avanços tecnológicos e ao rápido envelhecimento da população. A demanda por equipamentos destinados ao diagnóstico, prognóstico e tratamento registrou um aumento significativo desde o surgimento global da COVID-19. Esse fenômeno destacou a importância crescente dos dispositivos médicos na resposta a desafios de saúde emergentes e na busca por soluções eficazes em meio a cenários de pandemia.

Atualmente, fica claro que o simples ato de fabricar um dispositivo e integrá-lo ao setor de saúde está longe de ser suficiente. Os usuários agora anseiam por mais do que apenas um dispositivo isolado. Embora a demanda por cuidados de saúde continue a crescer, os governos ao redor do mundo estão direcionando seus esforços para reduzir custos, ao mesmo tempo em que buscam resultados aprimorados para seus pacientes.

Em suma, os usuários de equipamentos médico-hospitalares esperam hoje funcionalidades mais avançadas, como previsão de resultados clínicos, classificação avançada e outras capacidades que exigem inteligência incorporada. Este cenário reflete a necessidade

crecente de soluções de saúde mais sofisticadas e eficientes, alinhadas às expectativas dos pacientes e às metas de otimização de recursos orçamentários.

A integração da Inteligência Artificial (IA) na área da saúde representa um dos pilares estratégicos fundamentais para impulsionar avanços significativos no setor. Essa abordagem oferece a oportunidade não apenas de aumentar a eficiência operacional, mas também de reduzir custos, aprimorar os processos e transformar a prestação de cuidados de saúde. Reconhecendo a importância dessas inovações, reguladores em todo o mundo, como o Conselho Europeu (2017) e a Administração de Alimentos e *Food and Drug Administration* (FDA, 2020), têm enfatizado a necessidade de promover o uso dessas ferramentas inovadoras. A mudança de paradigma é evidente, e esta transição não apenas fortalece a promoção da saúde e a prevenção de doenças, mas também impulsiona a implementação da medicina personalizada. Diversos países estão elaborando estratégias e políticas nacionais voltadas para a Inteligência Artificial, buscando fomentar a pesquisa, o desenvolvimento e a adoção desses métodos e tecnologias inovadoras na área da saúde [38,39].

Diante do crescente volume de dados gerados na área da saúde, o potencial da aplicação da Inteligência Artificial (IA) é vasto, abrangendo desde aprimoramentos na tomada de decisões clínicas e saúde pública, até avanços significativos na pesquisa biomédica, desenvolvimento de medicamentos, gestão do sistema de saúde e reestruturação dos serviços. A análise do uso da IA em dispositivos médicos na área da saúde é realizada considerando não apenas a situação atual, mas também avaliando a evolução passada e antecipando as tendências futuras.

Este panorama abrangente reflete a capacidade transformadora da IA em diversos ambientes do setor de saúde, proporcionando benefícios significativos em todas as etapas de diferentes processos, desde diagnósticos mais precisos até eficiência operacional e inovação terapêutica.

O futuro da aplicação da Inteligência Artificial (IA) em dispositivos médicos apresenta perspectivas promissoras, especialmente na harmonização de normas e leis específicas que regulamentam esse setor em constante evolução. A *Food and Drug Administration* (FDA) já demonstrou avanços notáveis nesse contexto. Em contraste com os legisladores europeus, o FDA delineou sua visão sobre a Inteligência Artificial em um documento intitulado "Marca Regulatória Proposta para Modificações em *Software* Baseado em Inteligência Artificial/Aprendizado de Máquina (AI/ML) como um *Software Médico* (SaMD)", publicado em abril de 2019. Este documento aborda os desafios relacionados a sistemas de

aprendizagem contínua, destacando que dispositivos médicos previamente aprovados com base em algoritmos de IA eram muitas vezes caracterizados por "algoritmos bloqueados".

Embora os reguladores estejam voltados a essa questão complexa, líderes e fabricantes estão respondendo a esses desafios ao adaptar seus modelos de negócios tradicionais para abraçar abordagens mais inteligentes e inovadoras. Esse movimento reflete não apenas uma adaptação às mudanças regulatórias, mas também uma transformação proativa em direção a modelos de fabricação mais ágeis e eficientes, alinhados com as demandas do cenário emergente de dispositivos médicos baseados em Inteligência Artificial.

Um exemplo é a Medtronic, que está comprometida em integrar a Inteligência Artificial em seus processos existentes. Isso abrange áreas como imagens avançadas, robótica, navegação e um aumento no recrutamento para monitoramento remoto de pacientes. Um produto-chave da Medtronic é a plataforma pré-operatória denominada UNiD ASI, projetada para utilizar algoritmos de modelagem preditiva na reconstrução digital da coluna vertebral, permitindo medições precisas. Desenvolvido pela Medtronic, uma empresa francesa especializada em soluções cirúrgicas para neurocirurgiões e cirurgiões plásticos, o UNiD ASI destaca-se como um avanço notável. Por outro lado, a Philips adotou uma abordagem estratégica focada em diversas tendências de mercado, com ênfase particular em diagnósticos de Inteligência Artificial e aprimoramento de fluxos de trabalho com maior precisão. Em dezembro de 2020, a Philips fortaleceu sua posição nesse domínio ao assinar um acordo de fusão para adquirir a BioTelemetry por US\$ 2,8 bilhões. A BioTelemetry, especializada em diagnósticos cardíacos, monitores cardíacos vestíveis e análise de dados baseada em Inteligência Artificial, destaca-se pelo seu papel essencial na monitorização cardíaca fora do ambiente hospitalar. Essas estratégias refletem o compromisso das empresas líderes em saúde de abraçar as oportunidades oferecidas pela IA para impulsionar a excelência clínica e transformar os cuidados de saúde [40].

No cenário dos equipamentos médicos, a Inteligência Artificial representa um campo relativamente novo e dinâmico. Ao contrário de muitos dispositivos tradicionais, que são geralmente concebidos por equipes de materiais, engenheiros mecânicos e elétricos, os dispositivos médicos baseados em IA demandam especialização em programação e codificação de software. Essa mudança de paradigma destaca a importância crescente da interseção entre a tecnologia e a saúde, onde o conhecimento interdisciplinar desempenha um papel fundamental.

O futuro da aplicação da IA nesse contexto não se limita apenas ao aprimoramento da precisão no tratamento médico. Ele se estende também à prevenção de lesões e mortes

relacionadas a dispositivos médicos. Ao capacitar os dispositivos com capacidades inteligentes, como aprendizado de máquina e algoritmos preditivos, é possível antecipar potenciais problemas e otimizar a segurança dos pacientes. Essa abordagem inovadora não apenas redefine a eficácia dos tratamentos, mas coloca um foco crucial na segurança, representando um avanço significativo na evolução da tecnologia no campo da saúde.

Como as ferramentas de Inteligência Artificial podem ser adotadas no projeto e uso de dispositivos médicos, tal abordagem também pode ser usada para protocolos de manutenção de dispositivos médicos.

Um estudo recente apresentou resultados significativos no desenvolvimento de Redes Neurais Artificiais (ANNs) para prever problemas de desempenho em dispositivos médicos, utilizando dados provenientes de avaliações de conformidade. Estes dados foram extraídos de inspeções periódicas conduzidas por certificação ISO 17020 em laboratório, no período de 2015 a 2019. Para a criação das ANNs, foram empregadas 1.738 amostras de avaliação de conformidade de bombas perfusoras e de infusão. Destas, 80% (1.391 amostras) foram utilizadas durante a fase de desenvolvimento do sistema, enquanto as restantes 20% (346 amostras) foram reservadas para a validação posterior do desempenho do sistema.

Durante o desenvolvimento, o impacto no desempenho geral de precisão do sistema de diferentes números de neurônios na camada oculta e as funções de ativação foram testadas. Além disso, duas arquiteturas de redes neurais foram testadas: *feedforward* e *feedback*. Os resultados mostraram que a arquitetura de rede neural *feedforward* com 10 neurônios em uma única camada oculta têm o melhor desempenho. A precisão geral dessa rede neural é de 98,06% para previsão de desempenho de bombas perfusoras e 98,83% para previsão de desempenho de bombas de infusão. A rede neural recorrente resultou em precisão de 98,41% para ambas as bombas.

Os resultados mostram que a avaliação da conformidade dos dados obtidos através de inspeções anuais de dispositivos médicos podem ser usados com sucesso para previsão de desempenho de dispositivos médicos [41]. Esses resultados revelam que os dados de avaliação de conformidade provenientes de inspeções anuais em dispositivos médicos podem ser eficazmente empregados para prever o desempenho desses dispositivos. Este avanço promissor sugere uma aplicação prática e valiosa da inteligência artificial na gestão proativa e na otimização da confiabilidade operacional de dispositivos médicos essenciais.

Esses sistemas representam uma mudança de paradigma significativa, passando de um modelo de gerenciamento reativo e manutenção para um enfoque preditivo. Os resultados deste estudo evidenciam que a aplicação da Inteligência Artificial na Engenharia Clínica e no

gerenciamento de tecnologia em saúde não só aprimora a eficácia operacional, mas também proporciona benefícios tangíveis em termos de otimização de custos e gerenciamento eficiente de equipamentos médicos. Essa abordagem preditiva não apenas eleva a qualidade dos cuidados de saúde, mas também oferece um impacto positivo na gestão de recursos, promovendo uma abordagem mais proativa e eficaz para manter e aprimorar a infraestrutura médica.

5. CONCLUSÃO

Esta pesquisa destacou a importância da aplicação da Inteligência Artificial (IA) na otimização da predição de manutenção em equipamentos médico-hospitalares. A abordagem proposta, centrada em algoritmos de Aprendizado de Máquina, apresenta um potencial significativo para contribuir de maneira eficiente e precisa ao setor da saúde, pois os modelos inteligentes resultantes dessa abordagem têm a capacidade de oferecer resultados econômica e operacionalmente viáveis.

A pesquisa também evidenciou a constante evolução da IA no contexto dos dispositivos médicos, destacando a necessidade de aprimoramentos contínuos e atenção constante para alcançar seu pleno desenvolvimento e integração. A previsão de uma transição significativa nos fabricantes de dispositivos médicos até 2030, em direção a abordagens mais digitais, ressalta a importância de um quadro regulamentar sólido e de padrões internacionais relacionados à IA em dispositivos médicos. Organizações como ISO, IEC e IEEE desempenham um papel fundamental na padronização da gestão da qualidade dos dados e na aplicação responsável da IA, reconhecendo o impacto direto dessa tecnologia no bem-estar humano. Apesar dos obstáculos, a IA já provocou uma mudança profunda no modelo médico tradicional, melhorando a qualidade dos serviços médicos e ampliando a abrangência da atenção à saúde.

O modelo preditivo serve como um guia valioso para a melhoria de processos e garantia de qualidade em dispositivos médicos. A capacidade da IA em decifrar padrões nos dados históricos simplifica a tomada de decisões, agilizando a substituição e automação de tarefas de otimização de processos. A habilidade preditiva da manutenção oferecida pela IA permite que instituições de saúde melhorem o desempenho e ciclo de vida dos dispositivos, tomando decisões mais rápidas e eficientes. Entretanto, o futuro da IA na área da saúde traz incertezas quanto ao seu impacto total sobre a vida humana. A pesquisa destaca a necessidade de antecipar as inovações em desenvolvimento e enfrentar de maneira proativa questões éticas e práticas que possam surgir nesse cenário dinâmico e transformador.

Em síntese, a aplicação da IA na predição de manutenção em equipamentos médico-hospitalares representa uma evolução promissora para o setor da saúde, mas requer uma abordagem cautelosa e uma atenção contínua aos desafios éticos, práticos e regulatórios emergentes.

REFERÊNCIAS

1. KAUL, Vivek; ENSLIN, Sarah; GROSS, Seth A. History of artificial intelligence in medicine. **Gastrointestinal endoscopy**, v. 92, n. 4, p. 807-812, 2020. <https://doi.org/10.1016/j.gie.2020.06.040>
2. BEYAZ, Salih. A brief history of artificial intelligence and robotic surgery in orthopedics & traumatology and future expectations. **Joint Diseases and Related Surgery**, v. 31, n. 3, p. 653, 2020. <https://doi.org/10.5606/ehc.2020.75300>
3. HAMET, P.; TREMBLAY, J. Artificial intelligence in medicine. *Metabolism*. **69**, S36–S40 (2017). 18. Urban, G. et al. **Deep Learning Localizes and Identifies Polyps in Real Time With 96% Accuracy in Screening Colonoscopy**, 2017. <https://doi.org/10.1016/j.metabol.2017.01.011>
4. JIANG, Fei et al. Artificial intelligence in healthcare: past, present and future. **Stroke and vascular neurology**, v. 2, n. 4, 2017. <https://doi.org/10.1136/svn-2017-000101>
5. MITTELSTADT, Brent et al. Development of a surgical robot for cementless total hip replacement. **Robotica**, v. 11, n. 6, p. 553-560, 1993. <https://doi.org/10.1017/S0263574700019408>
6. FAUST, Russel A. (Ed.). **Robotics in surgery: history, current and future applications**. Nova Publishers, 2007.
7. RUFFLE, James K.; FARMER, Adam D.; AZIZ, Qasim. Artificial intelligence-assisted gastroenterology—promises and pitfalls. **Official journal of the American College of Gastroenterology| ACG**, v. 114, n. 3, p. 422-428, 2019. <https://doi.org/10.1038/s41395-018-0268-4>
8. KUDO, Shin-ei et al. Artificial intelligence and colonoscopy: Current status and future perspectives. **Digestive Endoscopy**, v. 31, n. 4, p. 363-371, 2019. <https://doi.org/10.1111/den.13340>

9. BORJALI, Alireza et al. Detecting total hip replacement prosthesis design on plain radiographs using deep convolutional neural network. **Journal of Orthopaedic Research®**, v. 38, n. 7, p. 1465-1471, 2020. <https://doi.org/10.1002/jor.24617>
10. BAUM, F. et al. Computer-aided detection in direct digital full-field mammography: initial results. **European radiology**, v. 12, p. 3015-3017, 2002. <https://doi.org/10.1007/s00330-002-1393-3>
11. MORTON, Marilyn J. et al. Screening mammograms: interpretation with computer-aided detection—prospective evaluation. **Radiology**, v. 239, n. 2, p. 375-383, 2006. <https://doi.org/10.1148/radiol.2392042121>
12. DE GROOF, Albert J. et al. Deep-learning system detects neoplasia in patients with Barrett’s esophagus with higher accuracy than endoscopists in a multistep training and validation study with benchmarking. **Gastroenterology**, v. 158, n. 4, p. 915-929. e4, 2020. <https://doi.org/10.1053/j.gastro.2019.11.030>
13. DING, Zhen et al. Gastroenterologist-level identification of small-bowel diseases and normal variants by capsule endoscopy using a deep-learning model. **Gastroenterology**, v. 157, n. 4, p. 1044-1054. e5, 2019. <https://doi.org/10.1053/j.gastro.2019.06.025>
14. HIRASAWA, Toshiaki et al. Application of artificial intelligence using a convolutional neural network for detecting gastric cancer in endoscopic images. **Gastric Cancer**, v. 21, p. 653-660, 2018. <https://doi.org/10.1007/s10120-018-0793-2>
15. DHAHRI, Habib et al. Automated breast cancer diagnosis based on machine learning algorithms. **Journal of healthcare engineering**, v. 2019, 2019. <https://doi.org/10.1155/2019/4253641>
16. WU, Qing; ZHAO, Wenbing. Small-cell lung cancer detection using a supervised machine learning algorithm. In: **2017 international symposium on computer science and intelligent controls (ISCSIC)**. IEEE, 2017. p. 88-91. <https://doi.org/10.1109/ISCSIC.2017.22>
17. RAJESWARI, S. et al. Detection and Classification of Various Types of Leukemia Using Image Processing, Transfer Learning and Ensemble Averaging Techniques. In:

- 2022 2nd Asian Conference on Innovation in Technology (ASIANCON)**. IEEE, 2022. p. 1-6. <https://doi.org/10.1109/ASIANCON55314.2022.9909377>
18. NIAZI, Seemal et al. Cardiovascular care in the era of machine learning enabled personalized medicine. In: **2020 International Conference on Information Networking (ICOIN)**. IEEE, 2020. p. 55-60. <https://doi.org/10.1109/ICOIN48656.2020.9016426>
 19. JAYATILAKE, Senerath Mudalige Don Alexis Chinthaka et al. Involvement of machine learning tools in healthcare decision making. **Journal of healthcare engineering**, v. 2021, 2021. <https://doi.org/10.1155/2021/6679512>
 20. AICH, Satyabrata et al. A supervised machine learning approach using different feature selection techniques on voice datasets for prediction of Parkinson's disease. In: **2019 21st International Conference on Advanced Communication Technology (ICACT)**. IEEE, 2019. p. 1116-1121. <https://doi.org/10.23919/ICACT.2019.8701961>
 21. CRUZ, Antonio Miguel. Evaluating record history of medical devices using association discovery and clustering techniques. **Expert systems with applications**, v. 40, n. 13, p. 5292-5305, 2013. <https://doi.org/10.1016/j.eswa.2013.03.034>
 22. DHILLON, B. S.; LIU, Y. Human error in maintenance: a review. **Journal of quality in maintenance engineering**, v. 12, n. 1, p. 21-36, 2006. <https://doi.org/10.1108/13552510610654510>
 23. VERBANO, Chiara; TURRA, Federica. A human factors and reliability approach to clinical risk management: Evidence from Italian cases. **Safety science**, v. 48, n. 5, p. 625-639, 2010. <https://doi.org/10.1016/j.ssci.2010.01.014>
 24. KUTOR, J. Kwaku; AGEDE, P.; ALI, Rashid Haruna. Maintenance practice, causes of failure and risk assessment of diagnostic medical equipment. **Journal of Biomedical Engineering and Medical Devices**, v. 2, n. 1, p. 123, 2017.
 25. MAHFOUD, Hassana; BARKANY, Abdellah El; BIYAALI, Ahmed El. Medical maintenance performance monitoring: a roadmap to efficient improvement. **International Journal of Productivity and Quality Management**, v. 22, n. 1, p. 117-140, 2017. <https://doi.org/10.1504/IJPQM.2017.085850>

26. ABD RAHMAN, Noorul Husna et al. Predicting medical device failure: a promise to reduce healthcare facilities cost through smart healthcare management. **PeerJ Computer Science**, v. 9, p. e1279, 2023. <https://doi.org/10.7717/peerj-cs.1279>
27. MAHFOUD, Hassana; EL BARKANY, Abdellah; EL BIYAALI, Ahmed. A hybrid decision-making model for maintenance prioritization in health care systems. **Am J Appl Sci**, v. 13, n. 4, p. 439-50, 2016. <https://doi.org/10.3844/ajassp.2016.439.450>
28. LOPES, Fernanda Moraes. Identificação de alta demanda de manutenção corretiva em equipamentos de radiodiagnóstico e determinação de desempenho através de fator de influência. 2019.
29. MANSO, Joana Maria Dias. **Práticas de gestão de equipamentos médicos no Hospital da Luz**. 2012. Tese de Doutorado.
30. HAUSER, Katja et al. Explainable artificial intelligence in skin cancer recognition: A systematic review. **European Journal of Cancer**, v. 167, p. 54-69, 2022. <https://doi.org/10.1016/j.ejca.2022.02.025>
31. LANGER, Markus et al. What do we want from Explainable Artificial Intelligence (XAI)?—A stakeholder perspective on XAI and a conceptual model guiding interdisciplinary XAI research. **Artificial Intelligence**, v. 296, p. 103473, 2021. <https://doi.org/10.1016/j.artint.2021.103473>
32. PINTO, Henrique Alves. A utilização da inteligência artificial no processo de tomada de decisões: por uma necessária accountability. **Revista de Informação Legislativa**, v. 57, n. 225, p. 43-60, 2020.
33. ALVES, Marco Antônio Sousa; DE ANDRADE, Otávio Morato. Da “caixa-preta” à “caixa de vidro”: o uso da explainable artificial intelligence (XAI) para reduzir a opacidade e enfrentar o enviesamento em modelos algorítmicos. **Direito Público**, v. 18, n. 100, 2021. <https://doi.org/10.11117/rdp.v18i100.5973>
34. BELSHER, Bradley E. et al. Prediction models for suicide attempts and deaths: a systematic review and simulation. **JAMA psychiatry**, v. 76, n. 6, p. 642-651, 2019. <https://doi.org/10.1001/jamapsychiatry.2019.0174>

35. KROLL, Joshua Alexander. **Accountable algorithms**. 2015. Tese de Doutorado. Princeton University.
36. WALLACH, Wendell; FRANKLIN, Stan; ALLEN, Colin. A conceptual and computational model of moral decision making in human and artificial agents. **Topics in cognitive science**, v. 2, n. 3, p. 454-485, 2010. <https://doi.org/10.1111/j.1756-8765.2010.01095.x>
37. DIETTERICH, Thomas G.; HORVITZ, Eric J. Rise of concerns about AI: reflections and directions. **Communications of the ACM**, v. 58, n. 10, p. 38-40, 2015. <https://doi.org/10.1145/2770869>
38. RAVÌ, Daniele et al. Deep learning for health informatics. **IEEE journal of biomedical and health informatics**, v. 21, n. 1, p. 4-21, 2016. <https://doi.org/10.1109/JBHI.2016.2636665>
39. LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep learning. **nature**, v. 521, n. 7553, p. 436-444, 2015. <https://doi.org/10.1038/nature14539>
40. BADNJEVIĆ, Almir; AVDIHODŽIĆ, Halida; GURBETA POKVIĆ, Lejla. Artificial intelligence in medical devices: Past, present and future. **Psychiatria Danubina**, v. 33, n. suppl 3, p. 101-106, 2021.
41. HRVAT, Faris et al. Artificial Neural Networks for prediction of medical device performance based on conformity assessment data: Infusion and perfusor pumps case study. In: **2020 9th Mediterranean conference on embedded computing (MECO)**. IEEE, 2020. p. 1-4. <https://doi.org/10.1109/MECO49872.2020.9134359>