



**MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DO TRIÂNGULO MINEIRO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA E TECNOLOGIA DE
MATERIAIS (PPGCTM)**

Guilherme Felipe Simão

**A INTELIGÊNCIA ARTIFICIAL COMO FERRAMENTA DE AUXÍLIO
DIAGNÓSTICO E ANÁLISE DE MATERIAIS EM BIOSSENSORES
ELETROQUÍMICOS**

**Uberaba
2023**

Guilherme Felipe Simão

**A INTELIGÊNCIA ARTIFICIAL COMO FERRAMENTA DE AUXÍLIO
DIAGNÓSTICO E ANÁLISE DE MATERIAIS EM BIOSSENSORES
ELETROQUÍMICOS**

Dissertação de Mestrado à ser apresentado ao
PPGCTM da UFTM para atender demanda
INSTITUCIONAL PGCTM/PROPPG/UFTM.

Orientador: Anderson Barbosa Lima

**Uberaba
2023**

**Catálogo na fonte: Biblioteca da Universidade Federal do
Triângulo Mineiro**

S596i Simão, Guilherme Felipe
 A Inteligência artificial como ferramenta de auxílio diagnóstico e
 análise de materiais em biossensores eletroquímicos / Guilherme Felipe
 Simão. -- 2023.
 57 p. : il., graf., tab.

 Dissertação (Mestrado em Ciência e Tecnologia de Materiais) --
 Universidade Federal do Triângulo Mineiro, Uberaba, MG, 2023
 Orientador: Prof. Dr. Anderson Barbosa Lima

 1. Inteligência artificial. 2. Diagnóstico diferencial. 3. Computação.
 4. Estatística - Análise. I. Lima, Anderson Barbosa. II. Universidade Federal
 do Triângulo Mineiro. III. Título.

CDU 004.8

GUILHERME FELIPE SIMÃO**A inteligência artificial como ferramenta de auxílio diagnóstico e análise de materiais em biossensores eletroquímicos.**

Dissertação apresentada ao Programa de Pós-Graduação em Ciência e Tecnologia de Materiais, área de concentração - Produtos Naturais e Sintéticos Bioativos, da Universidade Federal do Triângulo Mineiro como requisito parcial para obtenção do título de mestre.

Uberaba-MG, 15 de fevereiro de 2023

Banca Examinadora:

Prof. Dr. Anderson Barbosa Lima - Orientador
Universidade Federal do Triângulo Mineiro

Prof. Dr. Leandro Cruvinel Mendes
Universidade Federal do Triângulo Mineiro

Profa. Dra. Regina Massako Takeuchi
Universidade Federal de Uberlândia



Documento assinado eletronicamente por **Regina Massako Takeuchi, Usuário Externo**, em 02/06/2023, às 11:50, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#) e no art. 34 da [Portaria Reitoria/UFTM nº 87, de 17 de agosto de 2021](#).



Documento assinado eletronicamente por **LEANDRO CRUVINEL LEMES, Chefe do Núcleo de Empreendedorismo Substituto(a)**, em 04/06/2023, às 10:13, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#) e no art. 34 da [Portaria Reitoria/UFTM nº 87, de 17 de agosto de 2021](#).



Documento assinado eletronicamente por **ANDERSON BARBOSA LIMA, Professor do Magistério Superior**, em 05/06/2023, às 08:21, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#) e no art. 34 da [Portaria Reitoria/UFTM nº 87, de 17 de agosto de 2021](#).



A autenticidade deste documento pode ser conferida no site http://sei.uftm.edu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0937264** e o código CRC **869BF58D**.

DEDICATÓRIA

*Aos meus pais, **Edvaldo e Renata**, por sempre acreditar em mim e por terem abdicado de suas vidas em prol das realizações e da felicidade de seu filho.*

*À minha namorada **Beatriz Martins**, por sua preocupação, carinho e incentivo.*

*Aos **meus avós**, que desde os meus primeiros passos me incentivam no meio acadêmico.*

*À **Deus** que foi a minha maior força nos momentos difíceis. Nada disso teria sentido se vocês não existissem na minha vida.*

AGRADECIMENTOS

A Deus, que foi um verdadeiro guia nesse desafio e por me permitir realizar tantos sonhos nesta existência.

Ao Prof. Anderson, pela orientação, competência, responsabilidade e dedicação tão importantes durante a construção desse projeto. Tantas vezes que nos reunimos e, embora em algumas eu chegasse sem alguma solução, bastavam alguns minutos de apresentação e pesquisas que nós encontrávamos um caminho a ser seguido.

À Prof. Dra. Renata pelos seus conhecimentos e dedicação que foram fundamentais para que as implementações e diagnóstico na rede neural se tornassem realidade.

À minha namorada Beatriz Martins pela paciência, leituras, revisões, questionamentos e discussões sempre tão aprofundadas no objetivo de evoluir e aprimorar os resultados da rede neural.

A todos os demais amigos e amigas da UFTM, obrigado pelo convívio, amizade e apoio demonstrado.

“A tecnologia é só uma ferramenta, no que se refere a motivar as crianças e conseguir que trabalhem juntos, é um professor o recurso mais importante”

Bill Gates

RESUMO

As Ciências dos Materiais e Tecnologias da Informação estão cada vez mais contribuindo para o desenvolvimento científico e tecnológico em âmbito mundial. Dentro desta grande área, encontra-se a Inteligência Artificial (IA), um mecanismo que envolve o desenvolvimento e aprimoramento de softwares de decisões inteligentes, simulando assim, o raciocínio humano. Diante das diversas áreas de aplicação da IA, neste trabalho, foi desenvolvida uma rede neural que busca melhorar a experiência de resultados diagnósticos fornecidos por biossensores eletroquímicos. No protótipo deste software, conseguimos aprimorar a leitura de resultados liberada pelo voltamograma do biossensor eletroquímico cedido, onde foi possível identificar se o paciente era portador da doença alvo de análise. Neste trabalho, também foi possível analisar a melhor escolha de material a ser utilizado para a realização dos ensaios diagnósticos do dispositivo analisado. Desta forma, com o desenvolvimento desta Inteligência Artificial (IA), conseguimos avançar na formação de um protótipo que visa a melhora na acessibilidade e portabilidade dos diagnósticos desenvolvidos por biossensores eletroquímicos através de métodos presentes na computação.

Palavras-chaves: inteligência artificial; aperfeiçoamento; diagnóstico diferencial; análise de dados, computação.

ABSTRACT

Materials Sciences and Information Technologies are increasingly contributing to scientific and technological development worldwide. Within this large area, there is Artificial Intelligence (AI), a mechanism that involves the development and improvement of intelligent decision software, thus simulating human reasoning. Given the different areas of AI application, in this work, a neural network was developed that seeks to improve the experience of diagnostic results provided by electrochemical biosensors. In the prototype of this software, we were able to improve the reading of results released by the voltammogram of the electrochemical biosensor provided, where it was possible to identify whether the patient had the disease being analyzed. In this work, it was also possible to analyze the best choice of material to be used to carry out the diagnostic tests of the analyzed device. In this way, with the development of this artificial intelligence (AI), we were able to advance in the formation of a prototype that aims to improve the accessibility and portability of diagnoses developed by electrochemical biosensors through methods present in computing.

Key words: artificial intelligence; improvement; data analysis; differential diagnosis; computing.

LISTA DE ILUSTRAÇÕES

LISTA DE FIGURAS

Figura 1 - Rede Neural Simples e Rede Neural Profunda (Deep Learning).....	13
Figura 2 - Representação esquemática da área de abrangência da IA	14
Figura 3 - Marcos no desenvolvimento das redes neurais.	20
Figura 4 - Representação das etapas de Knowledge Discovery in Database.....	22
Figura 5 - Representação do código para a utilização do otimizador Adam	27
Figura 6 - Representação esquemática de um biossensor.	28
Figura 7 - Representação esquemática de um voltamograma cíclico.	30
Figura 8 - Fluxograma demonstrando as melhores combinações de parâmetros encontradas frente aos voltamogramas apresentados para o diagnóstico da enfermidade.....	38
Figura 9 - Resultado gerado pelo algoritmo durante o processo de otimização dos parâmetros alvos para o grafite e grafeno.....	39
Figura 10 - Matriz de análise para o diagnóstico da enfermidade	43
Figura 11 - Matriz de análise para o diagnóstico da enfermidade.	44

LISTA DE GRÁFICOS

Gráfico 1 - Gráfico de avaliação das métricas de Inteligência Artificial utilizando grafite.	46
Gráfico 2 - Gráfico de avaliação das métricas de Inteligência Artificial utilizando grafeno.	46

LISTA DE EQUAÇÕES

Equação 1 - Representação matemática da performance de neurônios em redes neurais	20
Equação 2 - Representação matemática da performance de neurônios em redes neurais	25
Equação 3 - Representação matemática da função de ativação sigmóide	26

LISTA DE ABREVIATURAS E SIGLAS

DC - Doença de Chagas

DTNs - Doenças Tropicais Negligenciadas

ELISA - Do inglês: “Enzyme-linked Immunosorbent Assay”

IA - Inteligência Artificial

IBM - Do inglês: “International Business Machines”

LVH - Do inglês: “Leishmaniose Visceral Human”

MIT - Do inglês: “Massachusetts Institute of Technology”

OMS - Organização Mundial da Saúde

PCR - Do inglês: “Polymerase Chain Reaction”

ReLu - Do inglês: “Rectified Linear Unit”

RNA - Redes Neurais Artificiais

SUS - Sistema Único de Saúde

VC - Voltametria Cíclica

CPUs - Do inglês: “Central Processing Units”

GPUs - Do inglês: “Graphics Processing Units”

TPUs - Do inglês : “Tensor Processing Units”

SUMÁRIO

1	INTRODUÇÃO	11
1.1	Histórico e conceituação da Inteligência Artificial (IA)	11
1.2	O papel da Inteligência Artificial em tarefas diagnósticas em biossensores eletroquímicos	14
1.3	Contribuições da Inteligência Artificial aplicadas à área da saúde	16
2	REFERENCIAL TEÓRICO	18
2.1	A Internet das coisas	18
2.2	TensorFlow	19
2.3	Aprendizado de Máquina	19
2.3.1	Knowledge Discovery in Databases	21
2.3.1	Processo de obtenção de dados	23
2.3.2	Perceptron	23
2.3.3	Dropout	24
2.3.4	ReLu	24
2.3.5	Sigmóide	25
2.3.6	Otimizador Adam	26
2.4	Biossensores eletroquímicos	27
3	OBJETIVOS	32
3.1	Objetivo Geral	32
3.2	Objetivos específicos	32
4	JUSTIFICATIVA	33
5	HIPÓTESE	34
6	MATERIAL E MÉTODOS	35
6.1	Inteligência Artificial	35
6.1.1	Tensorflow	35
6.1.2	Perceptron	35
6.1.3	Dropout	35
6.1.4	ReLu	36
6.1.5	Sigmóide	36
6.1.6	Otimizador Adam	36
6.2	Processo de Obtenção dos dados	36
6.2.1	Knowledge Discovery in Databases	36
6.3	Biossensores eletroquímicos	39
7	RESULTADOS & DISCUSSÃO	41
8	CONCLUSÃO	48
	REFERÊNCIAS	49

1 INTRODUÇÃO

Neste ponto, serão demonstrados o contexto e relevância do desenvolvimento da Inteligência Artificial proposta neste trabalho. Os dados históricos de criação e consolidação desta ciência serão abordados para gerar compreensão do tema estudado neste trabalho. Além do mais, relações entre as ciências dos materiais, ciências médicas e a Inteligência Artificial, bem como alguns exemplos de aplicações estarão presentes neste capítulo.

1.1 Histórico e conceituação da Inteligência Artificial (IA)

As revoluções tecnológicas proporcionadas pelos avanços da ciência e da globalização, gerou um grande fortalecimento dos sistemas científicos e avanços teóricos a respeito das ciências dos materiais aplicadas em Inteligência Artificial (IA). Com isso, novos meios de compartilhamento de dados computacionais foram gerados, ferramentas de armazenamento e processamento foram criadas de modo que as aplicações das ciências dos materiais foram adaptadas para suprir as necessidades cotidianas de áreas como a química, física e ciência dos materiais (SCHLEDER; FAZZIO, 2021).

O desenvolvimento de métodos ou dispositivos capazes de reproduzir a lógica humana está sendo objetivo de estudos da Inteligência Artificial (GOMES, 2010; LOBO, 2017). Historicamente, desde os primórdios da vida em sociedade, o homem tenta explicar as vertentes por trás do raciocínio de sua espécie e a mecanização deste processo foi efetuada no decorrer da história, assim, a fim de melhorar a robustez e a segurança no processo de aprendizado de máquinas, metodologias de aprimoramento foram criadas (DENG *et al.*, 2020).

A partir da década de 1950, o matemático Claude E. Shannon, um dos pioneiros no estudo e desenvolvimento da Inteligência Artificial (IA) publicou um artigo denominado “Programming a Computer for Playing Chess” na *Philosophical Magazine* que tinha como objetivo ensinar um computador a jogar xadrez (SHANNON, 1950). Entre os anos 1956 a 1974, considerados os anos de ouro para a IA, houveram várias revoluções científicas que influenciaram nos avanços tecnológicos observados atualmente (TAULLI, 2020). Em 1956, o termo Inteligência Artificial foi formalizado na Conferência de Dartmouth (KAUFMAN, 2020).

Nessa conferência, estavam reunidos diversos nomes consagrados na área, à exemplo, Nathan Rochester da IBM (International Business Machines Corporation), John McCarthy, Claude Shannon - referência no desenvolvimento da máquina de jogar xadrez,

além de muitos outros cientistas (COZMAN, 2021). Desde então, no decorrer de corridas tecnológicas experimentadas pelo mundo, avanços, investimentos e olhares foram sendo mais expressivos e vultosos nessa área e o desenvolvimento de vários ramos da ciência na intenção de fornecer à computadores com habilidades para efetuar funções com soluções típicas do cérebro humano vêm sendo desenvolvidos (GOMES, 2011).

Assim, nos anos 1957, Frank Rosenblatt desenvolveu e apresentou uma máquina, denominada de *Perceptron* para simular os processos biológicos que acontecem no cérebro, e assim, investigar o problema de reconhecimento de padrões (DENG *et al.*, 2020; ROQUE 2016). Em 1958, J. McCarthy criou a LISP (do inglês List Processing), uma linguagem de programação, baseada na estrutura de dados na forma de lista e desenvolvida para ser aplicada a programas Advice Taker e foi muito utilizada na programação algébrica para o processamento de listas em trabalhos de Inteligência Artificial específicos para os sistemas de IA da época (KARNICK, 2014).


Em 1964, surgiu o primeiro *chatbot* do mundo, batizado de ELIZA, nomenclatura inspirada na personagem da peça de teatro Pigmalião (1913), Eliza Doolittle, que foi sendo adaptado até os atuais software XiaoIce (SHUM, HE; LI, 2018). O desenvolvedor deste chat, Joseph Weizenbaum, desenvolveu sua criação no laboratório de Inteligência Artificial do Massachusetts Institute of Technology (MIT), esta tecnologia simulava uma psicanalista e era capaz de oferecer diálogos programados, o algoritmo era baseado em palavras chaves e estrutura sintática (CYSNEIROS, 1999; ARRESTEGUI, 2012).

Entre meados dos anos 1970 e início dos anos 1980, iniciou um período de estagnação na área de pesquisas sobre Inteligência Artificial, conhecido como inverno da Inteligência Artificial (COZMAN; PLONSKI; NERI, 2021). Essa terminologia foi baseada em uma teoria vigente na época, segundo a qual explosões nucleares apagariam o sol com fumaça e poeira, causando o congelamento da Terra e colocando a humanidade em extinção (TAULLI, 2020). Esse congelamento de investimentos e estudos em IA teve uma duração de quase duas décadas (SOUZA *et al.*, 2019).


As diversas inovações que seguiram dos anos 1990 até os anos 2000, culminaram em revoluções que influenciaram no surgimento e aplicação da aprendizagem profunda caracterizada pela aprendizagem por hierarquia de componentes dos níveis inferiores, que se destacou a partir dos anos 2000, (Figura 1), e assim, foi responsável por diversos avanços no reconhecimento de fala, reconhecimento de áudio e auxílio de sugestões de compras e filmes (BEZERRA, 2016). A partir desse marco, sistemas que eram capazes de utilizar redes neurais que imitam de forma mais efetiva, a maneira como o cérebro humano funciona.

Figura 1 - Rede Neural Simples e Rede Neural Profunda (Deep Learning)

Rede Neural Simples



Rede Neural Aprendizado Profundo



● Camada de entrada ● Camada oculta ● Camada de saída

Fonte: Nielsen, 2019 (Adaptado)

Enfim, essa complexidade observada nas redes neurais da primeira década do século XXI, possibilitou um retorno da Inteligência Artificial aos meios de pesquisas tecnológicas. Deste modo, grandes empresas, como a Google, Amazon, Microsoft e Apple, começam a investir neste setor da tecnologia e no lançamento de diversos recursos, voltados ao reconhecimento de voz que possibilita a formulação de pesquisas por comando de voz e a criação de aplicativos que se tornam assistentes pessoais de humanos, representam uma demanda ascendente observada na sociedade humana (JACINTHO; PENHA, 2016).


Os avanços continuaram ao longo dos anos, e, em 2015, surgiu a principal biblioteca utilizada neste artigo para auxiliar na detecção do nosso objetivo. O TensorFlow é uma biblioteca open- source, software de código aberto, para Machine Learning e Deep Learning desenvolvida pela Google (PANG, 2020). Em 2015, a Google liberou a biblioteca após anos de treinamento, e, desse momento em diante ela se tornou flexível e eficiente, com uma vasta opção de recursos, como: análise de imagens, processamento de linguagem natural e Deep Learning (RAMPASEK, 2016).

Desde então, os interesses de estudos e aprimorações da Inteligência Artificial vêm emergindo com mais força nos últimos anos, sendo aplicada a diversas áreas do conhecimento. Hoje, as Redes Neurais e os conceitos de Aprendizagem em conjunto com as grandes inovações no mundo tecnológico vêm sendo aplicados em áreas que não se achava possível sua utilização (MORAIS, 2010; GOMES, 2011).

Dessa forma, os sistemas desenvolvidos por Inteligência Artificial vêm sendo aprimorados e aplicados às diversas áreas do conhecimento humano, percorrendo os mais diversos campos relacionados à pesquisa e desenvolvimento tecnológico (Figura 2) para auxiliar em questões do cotidiano humano (MENDONÇA *et al.*, 2018). Apesar da

Inteligência Artificial ser uma ciência relativamente recente, tendo seu início marcado pela história humana após a Segunda Guerra Mundial, atualmente, ela abrange uma enorme variedade de áreas, desde o uso geral, como aprendizado e percepção, até tarefas específicas como jogos de xadrez, demonstração de teoremas matemáticos, criação de poesia e diagnóstico de doenças (GOMES, 2011; SILVA, 2018).

Figura 2 - Representação esquemática da área de abrangência da IA



Fonte: Gomes, 2011

Nota: Representação esquemática de áreas relacionadas ao campo de estudo da Inteligência Artificial atualmente. Comprovando assim, a multidisciplinaridade que envolve o campo de pesquisa relacionado à IA.

Assim, os dados expostos comprovam que, o avanço da Inteligência Artificial (IA), atualmente, representa uma das maiores revoluções no meio tecnológico (SARFATI, 2016). A partir desta tecnologia, foi possível uma evolução no desenvolvimento de máquinas que começaram a obter aprendizados baseados em experiências, que representa as entradas de dados que tem como objetivo aprimorar e proporcionar o aprendizado de máquinas para que desempenhem atividades, antes, relacionadas com as atividades típicas dos seres humanos (VEIGA; CADETE PIRES, 2018; DENG *et al.*, 2020).

1.2 O papel da Inteligência Artificial em tarefas diagnósticas em biossensores eletroquímicos

Os conhecimentos acerca dos materiais, bem como inovações nessas áreas são fundamentais para a continuidade dos avanços científicos (JAIN; PERSSON; CEDER, 2016). Já nas ciências médicas, os diagnósticos de biomoléculas são melhorados quando as ciências de materiais e a IA são aplicadas como adjuvantes (LOBO, 2017; GUARIZI; OLIVEIRA, 2014).

As metodologias diagnósticas por vezes são associadas a nanotecnologias que podem ser aprimoradas com o auxílio das ciências dos materiais, assim, por vezes é possível observar nanomateriais, associados a detecção de enfermidades, patógenos, proteínas, direcionamento terapêutico, monitoramento e outras funcionalidades (TEIXEIRA, 2021). Dentre as áreas multidisciplinares com aplicações relacionadas às ciências de materiais e aos setores biológicos estão as nanotecnologias aplicadas ao desenvolvimento de biossensores eletroquímicos

As aplicações de IA na análise dos diagnósticos eletroquímicos, para enfermidades, podem gerar o desenvolvimento de exames mais precisos, práticos, rápidos e eficientes que auxiliem no processo de controle de doenças infecciosas, correspondendo à avanços dessa demanda atual (HAUCK *et al.*, 2010; TALLURY *et al.*, 2010). Além do mais, é crescente o desenvolvimento de algoritmos que envolvem as identificações de correlações, criações, padronizações e consolidação dos conjuntos de dados (SCHLEDER; FAZZIO, 2021) que podem gerar os aprendizados de máquinas para serem aplicados no cotidiano da área médica.

Na criação de biossensores eletroquímicos com fins diagnósticos, tendencialmente, as plataformas não modificadas para análise da amostra quanto há presença do analito possuem resultados que refletem baixa sensibilidade, especificidade e seletividade (KHAN, 2017). Alternativamente a esse empecilho, materiais condutores estão sendo estudados e selecionados para serem aplicados em plataformas bases e como modificadores desses sistemas, onde, dentre os mais comuns, estão os polímeros condutores, os nanomateriais de carbono e os nanomateriais metálicos (MATUSCHEK; GOBEL; LISDAT, 2017; SANTOS, 2020). Neste sentido, os biossensores possuem atributos para suprir essas demandas, mas o sistema de escolha precisa de modificadores que melhorem os sistemas de detecção, e, a leitura de gráficos que refletem os resultados ainda é um empecilho vivenciado por esses diagnósticos.

Assim, a Inteligência Artificial pode mediar o processo de demanda dos biossensores eletroquímicos, das análises de nanopartículas, através de bancos de dados pré-alimentados com características relevantes para ambas as técnicas. Uma vez que, o conhecimento e aperfeiçoamento de materiais é o principal responsável pelas conquistas tecnológicas da humanidade, de modo que conhecer o perfil e propriedades dos materiais faz com que os avanços continuem a existir (SANTOS, 2020). Dessa forma, dentre os maiores destaques em relação às ciências de materiais e IA empregadas na área da saúde está o estudo de propriedades e estruturas de materiais e biomoléculas, além do aprimoramento de leituras diagnósticas que podem ser aplicadas nesse campo de trabalho.

1.3 Contribuições da Inteligência Artificial aplicadas à área da saúde

Os anseios por criar máquinas mais eficientes que obtivessem capacidades semelhantes à capacidade cerebral humana de captar, armazenar e utilizar informações do meio ambiente externo, influenciou a criação de redes de Inteligência Artificial (RIBEIRO; QUIMARÃES, 2018). Assim, a compreensão dos princípios e metodologias utilizadas para o desenvolvimento de redes neurais artificiais é uma demanda para pesquisadores envolvidos com essa metodologia.

Os neurônios humanos são base de inspiração para os sistemas de computação utilizados para criação de redes neurais (DENG *et al.*, 2020). Assim, os algoritmos de programação são responsáveis por fazer com que a conexão entre esses neurônios artificiais aconteça. Em termos práticos, atualmente é possível fazer a aplicação de redes neurais em tarefas que envolvem o cotidiano humano, como, reconhecimentos de ambiente, fala e fisionomias, estabelecimento de limites em tecnologias como redes sociais e dispositivos eletrônicos, utilização em diagnósticos e processos de aproximação nas relações sociais médico-paciente, detecção de fraudes em sistemas virtuais, otimização de logísticas, e, dentre outras muitas funcionalidades (MARQUES *et al.* 2020; GUARIZI; OLIVEIRA, 2014).

Na área de diagnósticos médicos, a criação de uma Inteligência Artificial que realize decisões rápidas e coerentes com decisões que seriam tomadas por seres humanos é uma demanda crescente (BRAGA *et al.*, 2019). Deste modo, a substituição da interpretação especializadas e complexas que necessite de um pessoal especializado por uma Inteligência Artificial que possa determinar o quadro de saúde do paciente representa um grande avanço tecnológico para esta área (LUGO-REYES; MALDONADO-COLÍN; MURATA, 2014; FARAHMAND *et al.*, 2017; GONZÁLEZ BENÍTEZ; ESTRADA SENTÍ; FEBLES ESTRADA, 2018).

Com a crescente revolução proporcionada pela IA, diversos grupos de pesquisa vêm desenvolvendo sistemas baseados nesta tecnologia, objetivando a melhoria nos processos de avaliações e decisões diagnósticas. À exemplo desses avanços, os sistemas envolvendo Inteligência Artificial já vem auxiliando em processos de soluções terapêuticas e interpretações de imagens das enfermidades investigadas pela equipe de saúde (SANTOS *et al.*, 2019), atuando em processos de diagnósticos precoces e decisões terapêuticas para câncer bucal (SANTANA *et al.*, 2021), para câncer colorretal (MITSALA *et al.*, 2021), para câncer cervical (BARRETO *et al.*, 2018), detecção de lesões malignas prevalentes em câncer de mama (DIAZ *et al.*, 2021), leitura e análises de eletrocardiogramas (MESQUITA, 2017),

diagnóstico de diabetes mellitus (XIANG *et al.*, 2021), detecção e diferenciação da COVID-19 de outras enfermidades pulmonares (LI *et al.*, 2020), auxílio no diagnóstico eletroquímico de campo para doenças infecciosas (KAUSHIK *et al.*, 2020), dentre outros.

Assim, o envolvimento e desenvolvimento de redes neurais que facilitem, aprimorem e agilizem os trabalhos humanos é uma crescente. Em especial, na medicina diagnóstica onde, em geral, observa-se uma robustez e sofisticação na análise e liberação de resultados. Assim, o desenvolvimento de técnicas especializadas em perspectivas de agilidade dos resultados que mantenha as características de sensibilidade, seletividade e especificidade representam uma demanda imediata desta área (MARTINS *et al.*, 2020).

Neste sentido, a incorporação de Inteligência Artificial (IA) a estas técnicas, é capaz de criar como possibilidade um diagnóstico mais amplamente entendível (MANICKAM *et al.*, 2022), possibilitando a liberação de um resultado de fácil interpretação classificando o dado como positivo ou negativo. Dessa forma, com a criação e aprimoramento de redes neurais especialistas nessas análises será possível impulsionar os avanços proporcionados por tais recursos.

2 REFERENCIAL TEÓRICO

Este capítulo tem o objetivo de apresentar o referencial teórico da pesquisa, bem como demonstrar os conceitos e contribuições da Inteligência Artificial e suas subseções. Assim, neste capítulo serão apresentados as principais definições e conteúdos que envolvem esta temática, bem como aplicações e referenciais acerca das metodologias utilizadas neste trabalho.

2.1 A Internet das coisas

O termo Internet das Coisas (Internet of Things ou IoT), pode ser classificado como uma tecnologia capaz de acoplar ambientes físicos e meios computacionais de percepção e transmissão de dados, que objetivem a criação de uma rede inteligente com uma vasta possibilidade de aplicação na sociedade humana (THAKKAR; LOHIYA, 2021). Apesar dessa tecnologia existir à algum tempo, a sua aplicabilidade no cotidiano humano ainda é considerado introdutório e suas aplicações em sensores, nanotecnologias e redes sem fio ainda não está disponível para a população em geral (CARRION; QUAARESMA, 2019; GODOI; ARAÚJO, 2019).

Em sistemas de saúde a aplicação da internet das coisas representa uma grande inovação capaz de propiciar maior desenvolvimento científico e tecnológico que buscam melhorar a experiência médico-paciente, bem como a simplificação, conexão e consequente otimização de recursos (ROSA; SOUZA; SILVA, 2020). Essa tecnologia, quando aplicada aos setores de saúde nacionais podem representar maior eficiência que reflete na qualidade de vida da população atingida através do aperfeiçoamentos de diagnósticos, tratamentos, acompanhamento de pacientes e criação de novos dispositivos úteis nesse âmbito (MOREIRA et. al., 2020; PAULA FILHO et al., 2020).

As investigações acerca dos benefícios da IoT durante a pandemia da COVID-19, constatarem que apesar dos grandes desafios envolvendo essa área, essas tecnologias vêm sendo aperfeiçoadas como ferramentas de combate, controle e enfrentamento a pandemias (COELHO et. al., 2020). Dessa forma, investimentos financeiros e intelectuais nessa área e no desenvolvimento de IA's, criação e alimentação de dados nas bibliotecas digitais, criação de programas e mecanismos digitais com benefícios em sistemas de saúde, representa uma demanda crescente da sociedade contemporânea e fomentos devem existir para gerar melhorias que alcancem uma maior parcela da população mundial.

2.2 TensorFlow

No processo de aprendizagem e treinamento de máquinas, existem bibliotecas de código aberto que facilitam os trabalhos realizados nessa área. Assim, a TensorFlow é uma dessas bibliotecas que foi criada pelo grupo de trabalho da Google Brain, sendo voltada para aprendizado e criação de redes neurais complexas, alcançadas através da flexibilidade e aplicação da lógica geral de construção, que é alcançada através da utilização do compilador algébrico XLA capaz de propiciar a operação em CPUs (Central Processing Units), GPUs (Graphics Processing Units), TPUs (Tensor Processing Units) e outros aparelhos (RIBEIRO; QUIMARÃES, 2018).

Essa biblioteca possibilita uma maior facilidade na programação e treinamento de redes neurais, bem como a eficiência na implementação de produções, com potencial de promover análise e modelagem de dados dos problemas propostos, sendo seus principais algoritmos escritos por C++ e Compute Unified Device Architecture (CUDA) (PANG, NIJKAMP, WU, 2020). Nesta biblioteca, são associados mecanismos de aprendizado profundo de computação e teorias de probabilidades adaptadas a realidade contemporânea que se tornam especializados em aplicações de Redes Neurais Artificiais, permitindo assim a operação em larga escala, com uma ampla gama de linguagens e em ambientes heterogêneos (ABADI et al., 2016; NASCIMENTO et al., 2020). Assim, a construção de trabalhos que visem a implementação de Inteligência Artificial, geralmente, está associada à pesquisa e implementação de dados presentes neste acervo.

2.3 Aprendizado de Máquina

O aprendizado de máquinas (ML) é uma metodologia presente em IA, voltada para a aprimoração de algoritmos computacionais simuladores da inteligência humana, esta metodologia busca o desenvolvimento de análises estatísticas (Equação 1) utilizando bases da big data como regressão linear, árvores de decisão e Naive Bayes (EL NAQA; MURPHY, 2015; LAL *et al.*, 2020). Nas ciências médicas, a utilização desta metodologia comprovou a sua soberania nos acertos de gravidade clínicas e decisões de tratamento quando comparadas as decisões humanas para a interpretação dos parâmetros de gravidade dos enfermos (CHURPEK *et al.*, 2016).

Equação 1: Representação matemática da performance de neurônios em redes neurais


$$y_j = \varphi \left(\sum_{i=1}^m x_i w_{ji} + b_j \right)$$

Fonte: Araújo, 2019

O cérebro humano é o núcleo de inteligência e aprendizagem do organismo, com capacidade de processar inúmeras informações em uma pequena quantidade de tempo (FREITAS, 2006). O nosso cérebro se desenvolve principalmente nos primeiros anos de vida, mas evolui por toda a vida. Inspirado nesse fato, o aprendizado de máquina consiste em computadores que treinam e aprendem a realizar tarefas similares a de seres humanos, por exemplo, reconhecimento de falas (GOMES, 2010); identificação de imagens (SANTOS *et al.*, 2019); realização de previsões (VALE; ZAMBIASI, 2000; CHUERUBIM; SILVA, 2019); entre outros.

Além do mais, a tecnologia proporcionada por IA permite que os sistemas desenvolvidos sobre a óptica ML utilizem técnicas de aprendizado profundo. Esses tipos de aprendizados são chamados de Deep Learning (DL) e se diferenciam pelo fato de não usar equações pré-definidas, sendo assim ele aprende através de várias camadas de processamento por meio de reconhecimento de padrões (LAL *et al.*, 2020). Antes do Deep Learning, diversas teorias existiram e corroboraram para o desenvolvimento das redes neurais da atualidade (Figura 3).

Figura 3 - Marcos no desenvolvimento das redes neurais



O algoritmo de Deep Learning é baseado em camadas de neurônios que tem como o objetivo processar os dados. Através desta metodologia, o processamento dos dados pode ocorrer de forma automática, se baseando em padrões e experiências obtidos de uma rede que possui múltiplas camadas de neurônio, incluindo camadas de entrada, ocultas e saída (DENG; YU, 2014; SANTANA *et al.*, 2022). A utilização dessas camadas proporcionam

melhorias na acurácia e eficiências dos sistemas computacionais. Sendo assim, a primeira camada da rede é chamada de camada de entrada e consiste na entrada de dados para a rede, enquanto a última camada é chamada de camada de saída (KALMET *et al.*, 2020).

As camadas intermediárias são utilizadas para que a informação seja passada para a entrada da próxima camada, possibilitando assim o reconhecimento de padrões através de uma função de ativação (CAPUCHINHO *et al.*, 2021). As funções de ativação são funções matemáticas na estrutura das redes neurais com o propósito de solucionar problemas complexos, trazendo o contexto para o mundo real, a função serve para informar ao neurônio se aquela informação é relevante ou não, ou seja, decide se o neurônio deve ser ativado ou não (PACHECO, PEREIRA, 2018).


Como o grande número de dados e possibilidades de combinações frente aos quadros clínicos individuais dos pacientes, dificultam na agilidade e precisão diagnóstica, bem como o tratamento de pacientes, a proposição de tecnologias envolvendo IA, ML e DL é uma crescente neste campo de atuação (LAL *et al.*, 2020).

A incorporação da IA em sistemas de saúde pode gerar benefícios nesta área, e, a cada dia, seu potencial tem sido amplamente estudado por pesquisadores da área. De modo que, é possível observar aplicações nestas ciências da saúde no que diz respeito à previsão de riscos, identificação precoce dos resultados de pacientes, identificação de populações de risco, escolhas e proposições diagnósticas e de tratamentos de pessoal, uma vez que, esses sistemas são especialistas em decifrar alguns padrões e agrupar pacientes pertinentes às enfermidades (FARAHMAND *et al.*, 2017; KAIESKI *et al.*, 2020; LORETO, LISBOA, MOREIRA, 2020).

2.3.1 Knowledge Discovery in Databases

O Knowledge Discovery in Database (KDD), tem como objetivo principal a compreensão de novos padrões que se tornem úteis e compreensíveis para o protótipo proposto. Este, pode ser organizado em etapas (Figura 4) que compreendem o pré-processamento e limpeza de dados, mineração e pós-processamento de dados. (BONAMIGO; CARVALHO; CUBAS, 2020; KACUTA, 2021).

Figura 4 - Representação das etapas de Knowledge Discovery in Database



Fonte: Kacuta, 2021

A etapa de seleção de dados, compreende na descoberta de conhecimentos através da criação ou seleção dos conjuntos de dados, vale ressaltar que, tanto no processo de criação quanto no processo de seleção, os dados obtidos precisam ter uma qualidade que reflitam no desenvolvimento de uma análise a partir do conhecimento de padrões (FAYYAD; PIATETSKY-SHAPIO; SMYTH, 1996).

Já, a etapa de pré-processamento, utiliza-se de técnicas de preparação do banco de dados de análise, como à exemplo a análise de outliers ou detecção de desvios, ocorrendo nesta fase a limpeza para evitar ruídos da base de dados e delimitação de limites que desconsiderem parâmetros irrelevantes para a análise, sendo assim, nesta fase podem ser utilizados algoritmos de Data Mining e métodos estatísticos sofisticados (MAIMON; ROKACH, 2009).

A etapa de transformação, redução ou projeção de dados, executam de forma irreversível a alteração de dados originais, nesta etapa, os dados são apresentados de forma compacta e compreensíveis para o usuário, sendo possível a seleção de características úteis para processo de representação de dados, redução de custos e aumento da eficiência de armazenamento. Nesta fase, estão disponíveis as etapas de redução da dimensão que busca diminuir a quantidade de variáveis aleatórias e assim tornar o processo mais informativo e com menor volume de dados; de clustering que busca o agrupamento dos dados; ou amostragem que consiste na utilização de um grande conjunto de dados para a criação de conjuntos menores que representem o todo, podendo ser realizada a partir de demonstrativos aleatórios simples, estratificados, adaptativos, entre outros. (KACUTA, 2021; MAIMON; ROKACH, 2005).

No processo de mineração de dados, busca a exploração dos dados pré-processados através de algoritmos e técnicas de agrupamento, predição, associação, análise descritiva e

detecção de anomalias, aprendizagem de máquinas, representando assim, um tema multidisciplinar (SILVA, 2019). Por fim, a etapa de interpretação e avaliação dos dados consiste na seleção de parâmetros úteis para a finalização do KDD (PANWAR; RAIWANI, 2014).

Assim, através do KDD é possível a aquisição de variáveis por bases de dados e, realizar o reconhecimento de padrões e relações que ajudem na avaliação e preenchimento de decisões pertinentes para a extração de dados que auxiliem no desenvolvimento da Inteligência Artificial alvo.

2.3.1 Processo de obtenção de dados

A obtenção dos dados ou mineração de dados, compreende na seleção de processos e etapas referentes aos elementos de análise. Assim, nesta fase, objetiva-se um aprimoramento da acurácia dos diagnósticos desenvolvidos, identificação de novos padrões e predição de etapas que busquem melhorar a eficiência do material analisado. Sendo assim, a detecção de anomalias, a aprendizagem de regra de associação, os clustering, a classificação, a regressão e a sumarização, são tarefas pertinentes para esta etapa dos trabalhos que envolvem a IA e podem ser realizadas a partir de etapas contidas no Knowledge Discovery in Databases.

2.3.2 Perceptron

Entre 1950 e 1960, o modelo Perceptron, sob inspirações de Warren McCulloch e Walter Pitts, foi criado por Frank Rosenblat, e tinha como objetivo, lidar com problemas relacionados ao reconhecimento de padrões naturais aos humanos que são considerados desafiadores para máquinas (SANTOS *et al.*, 2019). Desde então, os Sistemas Especialistas aplicados à IA são capazes de analisar especificamente determinada área, e, representam alternativas desenvolvidas na intenção de processar informações numéricas e conceituais, que geram dados obtidos e determinam aplicações (JHA *et al.*, 2019). Sendo assim, para esses sistemas, a metodologia Perceptron, representa o desenvolvimento de redes neurais que objetivam a solução de reconhecimento de padrões, que não são intuitivos no desenvolvimento de máquinas (DESAI; SHAH, 2021).

As redes neurais utilizam dados de entrada, para desenvolverem o seus aprendizados. Neste sentido, a escolha de parâmetros de entrada se tornam cruciais para o sucesso do modelo proposto, uma vez que, o conhecimento dessas análises são fornecidos no processo

de aprendizagem da IA (CHEVITARESE, 2010).

No processo de aprendizagem de máquinas, duas metodologias podem ser utilizadas, sendo elas, a batelada ou por ciclos a atualização só acontece depois que todos os padrões foram apresentados, e a incremental ou a padrão em que a atualização acontece após a apresentação de cada novo peso (SANTOS *et al.*, 2019). Desta forma, o reconhecimento de padrões, consiste em uma técnica onde, um sinal recebido na entrada de um sistema descrito como pertencente a uma categoria inserida em conjuntos de classes é reconhecido.

No modelo Perceptron, algumas etapas precisam ser cumpridas para que a metodologia apresente confiança significativa que reflitam na sua significância, sendo elas, a obtenção de amostras para entrada e saída, escolha aleatória de pesos com valores pequenos, realização da contagem de ciclos de treinamento, realizar ajustes de acordo com os pesos dos cálculos matemáticos que foram incrementados no sistema, verificação dos cálculos de erros que predizem a identificação de índices mínimos aceitáveis e em casos de índices inaceitáveis de erros reiniciar o processo a partir dos ciclos de treinamento (ROMANI, 2017). Assim, cumpridas essas etapas, a aplicação dessa ferramenta, pode otimizar a criação de IAs.

2.3.3 Dropout

A técnica de Dropout busca otimizar o desempenho de redes neurais, com objetivo de evitar que o modelo de Inteligência Artificial treinado decore os dados utilizados durante seu treinamento e aplique seus aprendizados em outros testes (MASSUCATO, 2018). Em termos práticos, através dessa técnica é possível desativar camadas que estão associadas com probabilidades ($p = 0,5$) descartando uma fração de forma aleatória e mudando a saída dos neurônios de uma rede neural.

Assim, essa metodologia é uma forma de regularização e aprimoramento da IA para que seja capaz de interpretar dados de maneira geral e não apenas um tipo de dado específico, treinando-a com diferentes subtipos de dados e oferecendo combinações exponenciais das redes neurais. Além do mais, com auxílio dessa técnica é possível evitar o overfitting e estabelecer uma aquisição de dados independentes (SRIVASTAVA *et al.*, 2014; SOUZA; GOMES, 2019).

2.3.4 ReLu

A função de Unidade Linear Retificada (ReLu) torna-se necessária em tarefas que

envolvam a ativação na extração de características relevantes, verificação da função a partir da velocidade de convergência do gradiente e aprendizagem profunda, através da função presente na equação 2, representando bom custo-benefício computacional para os resultados obtidos (NWANKPA *et al.*, 2018).

Equação 2 - Representação matemática da performance de neurônios em redes neurais

$$f(x) = x^+ = \max(0, x)$$

Fonte: Araújo, 2019

Sendo assim, nesta função, a inclusão de dados negativos irá gerar o zero como resultado. Sob essa ótica, aqueles resultados que após realizarem a soma ponderada apresentarem resultados negativos, tendem a gerar como resposta uma unidade vazia, ou seja, ainda no treinamento de dados as variáveis inseridas poderão deixar de existir (LU *et al.*, 2019).

Na função ReLu, o overfitting permite que os dados não gerem automação com resultados infundados em conhecimentos parciais obtidos pela rede neural, tornando essa metodologia e suas generalizações não paramétricas e paramétricas estáticas (CHEN *et al.*, 2020). Neste efeito, as chances de adaptação dos dados durante o treinamento que podem convergir em um mau aprendizado são reduzidas, e assim, o algoritmo se torna mais pertinente ao ideal almejado.

Através da rede neural residual profunda, trabalhos de classificações podem ser construídos, por um sistema de três fases, que compreendam o pré-processamento, a extração de características e a classificação (ALENEZI; ARMGHAN; POLAT, 2023). Desta forma, a partir do exposto, pode-se inferir que tomadas as cautelas necessárias, em trabalhos que envolvam a classificação de parâmetros, a função ReLu pode representar um grande ganho metodológico para extração de características pertinentes ao objeto de estudo.

2.3.5 Sigmóide

No processo de decisão quanto a ativação ou não de um neurônio, as funções de ativação são responsáveis por essa deliberação que são tomadas de acordo com a importância da informação recebida por esse neurônio, dentre essas funções, encontra-se a função sigmóide (RIZZO; CANATO, 2020).

Na criação de uma Inteligência Artificial, a função de ativação presente geralmente na última camada nas redes neurais de classificação, faz-se necessária, como por exemplo, a função de ativação sigmóide, o x da equação pode assumir qualquer valor positivo e negativo desde que a função $f(x)$ esteja compreendida no intervalo aberto de 0 a +1, representada matematicamente na Equação 3 (ARAÚJO, 2019; SOUSA, 2022). Desta forma, a utilização de funções não-lineares podem tornar essa rede mais precisa, uma vez que, a saída obtida é proveniente da amostra utilizada para o treinamento (WOLFRANN *et al.*, 2019).

Equação 3: Representação matemática da função de ativação sigmóide

$$\varphi(x) = \frac{1}{1 + e^{-x}}$$

Fonte: Araújo, 2019

Na criação de redes neurais complexas, a função sigmóide é utilizada pois, consegue classificar qualquer valor entre 0 e 1, realizando a saída não lineares dos neurônios, de modo que torna mais acessível a decisão de qual valor será positivo e qual será negativo (NASCIMENTO, 2021).

As ativações não-lineares precisam obedecer a condições que auxiliem na precisão do método aplicado. Assim, para se tornar interessante à sua aplicação é necessário que esta apresente a capacidade de ter as mesmas probabilidades de ser positivo ou negativo. Neste sentido, a função de ativação sigmóide apresentam gradiente que tende a zero quando o aprendizado não foi efetivo na saída, o que pode auxiliar em problemas que envolvem classificações, apesar de poder aumentar o custo computacional e afetar os níveis de precisão do método (LIMA *et al.*, 2019;).

Logo, para que as aplicação se torne mais rentáveis e justifique a utilização dessa função, essas funções não devem produzir resultados que tendem a ser constantes, precisam ser capazes de realizar uma derivada calculada em cada camada para cada operação matemática feita e realizar a previsão da probabilidade como uma saída (ARAÚJO, 2019).

2.3.6 Otimizador Adam

Os algoritmos de otimização são implementados para aprimorar os trabalhos. O objetivo do otimizador é especificar a solução em valores bem definidos, de modo que essa teoria busca fazer análises de algoritmos e solucionar problemáticas de estruturas das funções inseridas em redes neurais.

O otimizador Adam fundamenta-se em gradientes de primeira ordem, e assim, gera deduções de ordem inferior, calculando as taxas de aprendizagem adaptativas individuais para os parâmetros e aprendizagem dos gradientes iniciais (RIBEIRO *et al.*, 2020). Neste otimizar, as médias exponenciais decrescentes dos gradientes anteriores são mantidas, sendo necessárias nesta metodologia a utilização de informações dos dicionários m e v para a utilização do código (Figura 5), devendo esses vetores possuírem formato semelhante aos parâmetros atualizados (TAQI *et al.*, 2018; JERONYMO, 2019).

Figura 5 - Representação do código para a utilização do otimizador Adam

```

Require:  $\alpha$ : Stepsize
Require:  $\beta_1, \beta_2 \in [0, 1]$ : Exponential decay rates for the moment estimates
Require:  $f(\theta)$ : Stochastic objective function with parameters  $\theta$ 
Require:  $\theta_0$ : Initial parameter vector
 $m_0 \leftarrow 0$  (Initialize 1st moment vector)
 $v_0 \leftarrow 0$  (Initialize 2nd moment vector)
 $t \leftarrow 0$  (Initialize timestep)
while  $\theta_t$  not converged do
   $t \leftarrow t + 1$ 
   $g_t \leftarrow \nabla_{\theta} f_t(\theta_{t-1})$  (Get gradients w.r.t. stochastic objective at timestep  $t$ )
   $m_t \leftarrow \beta_1 \cdot m_{t-1} + (1 - \beta_1) \cdot g_t$  (Update biased first moment estimate)
   $v_t \leftarrow \beta_2 \cdot v_{t-1} + (1 - \beta_2) \cdot g_t^2$  (Update biased second raw moment estimate)
   $\hat{m}_t \leftarrow m_t / (1 - \beta_1^t)$  (Compute bias-corrected first moment estimate)
   $\hat{v}_t \leftarrow v_t / (1 - \beta_2^t)$  (Compute bias-corrected second raw moment estimate)
   $\theta_t \leftarrow \theta_{t-1} - \alpha \cdot \hat{m}_t / (\sqrt{\hat{v}_t} + \epsilon)$  (Update parameters)
end while
return  $\theta_t$  (Resulting parameters)

```

Fonte: Jeronimo, 2019

Em suma, a principal funcionalidade relacionada aos otimizadores está na capacidade de diminuir as discrepâncias existentes entre os dados esperados na relação existente entre a perda e custo na Inteligência Artificial, aperfeiçoando assim a capacidade analítica do modelo proposto.


2.4 Biossensores eletroquímicos

Os biossensores eletroquímicos têm sido amplamente utilizados em várias áreas científicas relacionados à detecção de processos biológicos (BRAININA, 1987). O termo biossensores eletroquímicos é utilizado para a construção de uma plataforma diagnóstica no setor clínico. Este método, quando comparado a metodologias disponíveis no mercado apresenta vantagens como seletividade, especificidade, baixo custo, facilidade de automação, dentre outras (BARROS *et al.*, 2022). Entretanto, estas ferramentas não podem assegurar uma substituição das técnicas analíticas clássicas, tornando-se uma ferramenta de complemento aos testes já existentes, uma vez que, em alguns casos a metodologia venha a

apresentar problemas de estabilidade (ROSATTO, 2000).

O funcionamento do biossensor eletroquímico como sistema analítico de detecção é constituído por interação entre componentes biológicos. Estas substâncias, são acopladas a uma superfície de transdutores eletroquímicos. Assim, a princípio, ao estar conectado ao transdutor, o sinal biológico do biossensor é transformado em sinal elétrico, e esse sinal é passível de ser quantificado (Figura 6).

Figura 6 - Representação esquemática de um biossensor



Fonte: Loguercio, 2019 (adaptado)

Nota: O Biossensor Eletroquímico é composto de algumas fases, aqui explicadas. Fase de reconhecimento biológico: primeira fase de interação existente entre as biomoléculas. Após a fase de reconhecimento molecular, um sinal é emitido ao transdutor, no estudo em questão, um transdutor eletroquímico. Por fim, um sinal elétrico é emitido ao computador, para que o mesmo seja quantificado e analisado.

Dentre os diagnósticos disponíveis nos sistemas de saúde, os biossensores eletroquímicos são sistemas analíticos de detecção constituídos por interação entre os componentes biológicos, que apresentam inúmeras características relevantes e necessárias para um diagnóstico efetivo (MARTINS *et al.*, 2020). Contudo, esses dispositivos apresentam resultados que necessitam de avaliações complexas que podem interferir no seu sistema de acessibilidade. E, frente às possíveis limitações inerentes em algumas técnicas diagnósticas, que sejam passíveis de intervenções, a Inteligência Artificial (IA) pode ser acoplada como uma metodologia auxiliar, desenvolvida para resolver problemas.


Os biossensores eletroquímicos é capaz de fornecer um conjunto de informações, sendo os sistemas voltamétricos comumente utilizados, que podem suprir a base de dados e de trabalhos que a IA necessita, e, simultaneamente a este processo, a IA é capaz de fornecer soluções aos desafios encontrados no processo de validação de um método a partir de um biossensor diagnóstico.

2.4.1 Voltametria Cíclica

Em biossensores eletroquímicos, as principais técnicas de análises comumente utilizadas são, as voltamétricas onde compreende-se a voltametria de onda quadrada; voltametria de pulso diferencial e voltametria cíclica, (TURNER, 2013). A técnica de voltametria é utilizada em biossensores eletroquímicos, a fim de gerar informações qualitativas e quantitativas sobre os processos de oxidação e redução de uma substância que acontece nas superfícies de eletrodos (SILVA, 2020). Nestas análises, o aparelho denominado de potenciostato, faz varreduras de potenciais e realiza as leituras de intensidade de correntes, assim neste sistema, curvas representativas da relação corrente-potencial são geradas e o gráfico de voltamograma é produzido (SONG *et al.*, 2016).

Os métodos voltamétricos podem apresentar diferentes objetivos de análise, o que diferencia os tipos de representações possíveis. Na técnica de voltametria cíclica (CV Cyclic Voltammetry), os processos de oxi-redução das substâncias podem ser observados. Esse processo, realiza uma varredura linear do potencial nos sentidos positivos e negativos (figura 7), onde no sentido positivo os picos anódicos (E_{pa}) e a corrente de pico anódico (I_{pa}) são obtidos, ao passo que, no sentido negativo os picos catódicos (E_{pc}) e a corrente de pico catódico (I_{pc}) são representados, e, esse conjunto de varreduras gera o voltamograma cíclico (ELGRISHI *et al.*, 2018). Neste sentido, no eixo x pode-se observar o sistema, neste caso designando o potencial aplicado (E), ao passo que, o eixo y, representa a reação, neste caso, designado corrente (i) (ELGRISHI *et al.*, 2018). Assim, em CV de uma mesma substância, a índices altos de intensidade da corrente representam maiores níveis de concentrações de substâncias (POSSEBON, 2022).

Figura 7 - Representação esquemática de um voltamograma cíclico



Fonte: Silva, 2020 pegar a de Elgrishi *et al.*, 2018

Deste modo, a Inteligência Artificial, como metodologia de auxílio em leituras diagnósticas, pode avaliar os pontos de corrente existentes em voltametrias cíclicas, que determina a positividade ou negatividade do paciente frente a enfermidade analisada. Podendo assim, ser encarada como uma metodologia de predição do futuro das técnicas diagnósticas, de forma que os impasses dos diagnósticos de processos biológicos complexos, que envolvem a utilização de pessoal altamente capacitado, podem ser otimizados de maneira eficiente, facilitada e promissora.

Os trabalhos que envolvem aplicações de inteligência artificial, precisam se basear no aprimoramento dos eixos de extração, armazenamento, transmissão e processamento de dados. Esses investimentos quando aplicados de forma correta e coerente aumentam as chances de criação de redes neurais eficientes que indiquem boas chances de crescimento do produto ou empresa envolvidos nesse desenvolvimento (CARVALHO, 2021).

2.4.2 Eletrodos

Os biossensores eletroquímicos podem sofrer algumas modificações em seus eletrodos que contribuam com a melhora de sua performance frente às biomoléculas analisadas. A escolha de materiais modificadores é feita após estudos de relações entre os alvos de detecção e os materiais presentes nos eletrodos. Os sistemas baseados em inteligência artificial são capazes de prever ligações, propriedades e performances de materiais para melhorar a qualidade e custo-benefício dos biossensores (ABOU ARABI, 2020).

Os eletrodos impressos, comumente utilizados na atualidade, são fabricados a partir da deposição de um material sobre um suporte de PVC, cerâmica de alumina, papel, dentre

outros (SOUZA, 1997). Quando baseados em carbono possuem como vantagem possuírem atividade superficial elevada o que possibilita sua passivação frente à incorporação de biomoléculas, além de abundância e facilidade de obtenção de seu material, ampla janela de potencial e menor custo financeiro para a sua aquisição (CARIDADE, 2008).

O carbono possui relevante polimorfismo estrutural guiado pelos tipos de ligações e hibridizações destes materiais, estabilidade química que possibilitam a existência de ligações fortes em estruturas que envolvem carbono-carbono e ampla faixa potencial de trabalho (CARIDADE, 2008; COUTO, 2006). Mas, quando comparados às substâncias metálicas, eles apresentam reações de oxirredução mais lentas e menor condutividade elétrica. (BAIO et al., 2014). Assim, materiais a base de carbono são de interesse para eletroanálises, de modo que podem apresentar características de condutor ou semicondutor à depender da metodologia empregada e por vezes são utilizados como plataforma base de detecções eletroquímicas baseadas em modificações com ouro (SONG *et al*, 2016).

As metodologias diagnósticas, em especial os biossensores eletroquímicos, quando modificadas com metais condutores tendem a apresentar vantagens elétricas relevantes para o desenvolvimento do método, tais como aumento da área superficial, eletrocatalise, controle do ambiente e transporte de massas (WELCH; COMPTON, 2006). Dentre os metais mais utilizados para a construção desses dispositivos com performance melhorada estão o ouro, rutênio, cobre, ferro e níquel, uma vez que estes podem ser usados como transdutores proporcionarem melhorias nos processos de identificação de analitos (PENN; HE; NATAN, 2003).

Diante dos materiais anteriormente citados, o ouro em forma de partícula apresenta propriedades interessantes como compatibilidade biológica, imobilização estável, atividade catalítica favorável devida a razão área superficial e volume, boa resistência mecânica e transferência de elétrons livre de mediadores (WELCH; COMPTON, 2006; PINGARRÓN; YAÑEZ-SEDEÑO; GONZÁLEZ-CORTÉS, 2008). E, frente a essas possibilidades, a incorporação desses materiais no diagnóstico de doenças deve ser avaliada quanto a sua melhora na performance analítica.

Deste modo, esta proposta constata o desenvolvimento de uma Inteligência Artificial (IA) capaz de identificar processos envolvidos na detecção de moléculas orgânicas selecionadas nos biossensores eletroquímicos. A técnica desenvolvida permite a ampliação e decodificação de leituras complexas provenientes dos testes realizados em biossensores eletroquímicos, à vista disso, será possível impulsionar os avanços proporcionados por estas metodologias diagnósticas.

3 OBJETIVOS

3.1 Objetivo Geral

O objetivo geral deste estudo foi desenvolver e validar uma técnica de análise, utilizando Inteligência Artificial, para auxiliar em resultados proporcionados através do diagnóstico analítico realizado por biossensores eletroquímicos. Além do mais, neste trabalho foi desenvolvida uma IA inicial, que busca diferenciar a performance dos materiais utilizados no biossensor eletroquímico analisado. Esta ferramenta buscou colaborar no auxílio da resolução de questões relacionadas à saúde pública do Brasil.

3.2 Objetivos específicos

A partir do exposto nas teorias sobre as eficiências acerca da Inteligência Artificial, pretendemos através deste trabalho, resolver detalhadamente:

- Desenvolver uma Inteligência Artificial para auxiliar no processo de interpretação dos resultados proporcionados pelos biossensores eletroquímicos;
- Avaliar com auxílio da metodologia desenvolvida, os dados fornecidos pelas plataformas eletroquímicas e compará-los para verificar através da IA os melhores resultados para o desenvolvimento de ferramentas diagnósticas;
- Investigar e comparar diferentes materiais nos eletrodos para apontar aqueles com melhores performances para os diagnósticos;
- Investigar através de uma Inteligência Artificial, os materiais que poderão facilitar as análises no modelo diagnóstico proposto.

4 JUSTIFICATIVA

A presente proposta visa identificar os materiais envolvidos nos processos da detecção de moléculas selecionadas em biossensores eletroquímicos. Além do mais, os biossensores eletroquímicos são plataformas diagnósticas inovadoras, mas que, por vezes, apresentam resultados que necessitam de avaliações complexas, através da IA, buscamos facilitar essas análises de enfermidades e tornar esse processo de identificação de pacientes positivos ou negativos mais acessível à profissionais não especialistas em métodos eletroquímicos.

5 HIPÓTESE

A Inteligência Artificial possui propriedades de quantificação que vão de encontro às necessidades estatísticas dos testes diagnósticos. Os sensores eletroquímicos possuem propriedades valiosas de diagnósticos aplicados às investigações, podendo estar relacionado a uma alta sensibilidade, seletividade, rapidez de execução e excelente custo-benefício. Dessa forma, aliado ao sistema de Inteligência Artificial, o biossensor poderá ser um método de detecção mais eficiente, superando expectativas de materiais já disponíveis no mercado. Além do mais, os diferentes materiais quando inseridos em plataformas eletroquímicas podem melhorar os processos de análises e com auxílio da IA é possível verificar a curto prazo aqueles que apresentam melhor performance.

6 MATERIAL E MÉTODOS

O projeto foi produzido através do Programa de Pós-Graduação em Ciência e Tecnologia de Materiais, da Universidade Federal do Triângulo Mineiro (UFTM) – Uberaba.

6.1 Inteligência Artificial

A presente proposta visa desenvolver uma Inteligência Artificial (IA) do tipo *Perceptron* de Multicamadas que visa a utilização de um número indeterminado de neurônios para prever uma saída onde seja capaz de identificar processos na detecção de moléculas selecionadas em biossensores eletroquímicos. Os biossensores eletroquímicos são plataformas diagnósticas inovadoras, mas que apresentam resultados que necessitam de avaliações complexas. Já a IA, cria como possibilidade um diagnóstico mais amplamente entendível, à exemplo, um resultado dado como positivo ou negativo, assim, foi possível impulsionar os avanços proporcionados por metodologias diagnósticas. Além do mais, com o auxílio de redes neurais, é possível facilitar a tomada de decisões, no que diz respeito à avaliação do melhor material a ser utilizado para o desenvolvimento de um biossensor eletroquímico eficiente.

6.1.1 Tensorflow

O tensorflow é uma biblioteca de código aberto que tem como objetivo auxiliar a criação de redes neurais. Foi desenvolvida pela Google em 2015 e atualmente tem estado entre as principais referências da área de Inteligência Artificial. Sendo assim, foi utilizada a biblioteca na linguagem Python para a criação da rede neural.

6.1.2 Perceptron

Foi desenvolvido o modelo neural composto por uma camada de entrada com 14 neurônios, duas camadas ocultas com 50 neurônios cada uma e uma camada de saída composta por um único neurônio. Esta combinação foi utilizada em ambos os materiais estudados nesta fase que são o grafite eletrodepositado com ouro e o grafeno eletrodepositado com ouro.

6.1.3 Dropout

No presente estudo, essa técnica foi utilizada durante o treinamento da IA, no

processo de construção dos ciclos de treinamento utilizamos um dropout de 20% na tentativa de evitar possíveis casos de overfitting durante o treinamento da rede neural desenvolvida.

6.1.4 ReLu

A função de ativação ReLu foi utilizada nas camadas ocultas para aperfeiçoamento dos cálculos entre os neurônios.

6.1.5 Sigmóide

A função de ativação Sigmóide foi utilizada na camada de saída para que pudéssemos classificar o resultado entre 0 e 1, sendo assim, o mais próximo de 1 é positivo e quanto mais próximo de 0 sendo um paciente negativo para a leishmaniose.

6.1.6 Otimizador Adam

Neste trabalho, o otimizador Adam foi aplicado para técnica de otimização da descida de gradiente, pois apresenta excelentes resultados tanto em nível de performance quanto em velocidade de treinamento.

6.2 Processo de Obtenção dos dados

A Mineração de Dados deste trabalho concerne ao exame das informações e construção de relações não explícitas existentes entre os voltamogramas cíclicos gerados pela metodologia de biossensores eletroquímicos, que foram usados em modelos com capacidade preditiva e explanatória. Em uma etapa posterior, os dados obtidos foram consolidados, formulando assim, uma estrutura conveniente para exploração e armazenamento.

6.2.1 Knowledge Discovery in Databases

As cinco etapas do processo KDD descritas na seção 2 deste trabalho foram aqui abordadas. O ponto inicial do KDD é na escolha ou seleção dos dados de análise de acordo com nosso objetivo, neste caso, são os pacientes positivos e negativos para leishmaniose e Doença de Chagas. Assim, foram selecionados 4 grupos de pacientes os quais foram separados em 10 pacientes identificados como positivos para a doença de Leishmaniose, 5

pacientes negativos para a doença de Leishmaniose, 2 pacientes positivos para a doença de Chagas e 3 pacientes negativos para a doença de Chagas. Essa primeira seleção foi utilizada para testar o biossensor utilizando o material de Grafite eletrodepositado com ouro.

Um adendo ao ponto inicial dessa fase de seleção foi a separação do grupo de pacientes para a testagem no eletrodo de Grafeno eletrodepositado com ouro, onde foram divididos em 24 pacientes identificados como positivos para a doença de Leishmaniose, 8 pacientes negativos para a doença de Leishmaniose, 2 pacientes positivos para a doença de Chagas e 3 pacientes negativos para a doença de Chagas.

O segundo ponto é o pré-processamento dos dados, onde foram utilizadas funções em Python com o intuito de remover os valores nulos, duplicados, inconsistentes ou errados, como os dados da fase de seleção são pequenos, essa fase não impactou na quantidade de dados. Após a limpeza dos dados foi observado um desequilíbrio entre as amostragens, então a técnica de SMOTE foi utilizada para que pudesse haver a geração de amostras sintéticas, pois espera-se que as classes positivo e negativo sejam um pouco equilibradas.


O terceiro ponto é a transformação desses dados, nesta etapa, objetiva-se um aprimoramento da acurácia dos diagnósticos desenvolvidos, identificação de novos padrões e predição de etapas que busquem melhorar a eficiência do material analisado.

Sendo assim, foram utilizadas técnicas para obter a corrente do pico anódico através de uma função utilizando a linguagem Python nas amostras da solução de Ferro-ferri cianeto de potássio ($[\text{Fe}(\text{CN})_6]^{3-/4}$ ou FF, sonda redox utilizada no desenvolvimento de biossensores eletroquímicos) e do antígeno, ambos em 3 ciclos no eletrodo. Após identificar esses picos, realizamos a média entre as correntes dos picos anódicos utilizando o FF e o antígeno. Essas médias ajudaram a elevar a acurácia da rede neural e foram utilizados como camada de entrada. Outro ponto importante para a camada de entrada, foi acrescentar a diferença entre os valores de corrente do pico anódico de FF e do antígeno, a diferença entre os picos foi fundamental para que a rede aprendesse novos padrões e melhorasse o overfitting que estava sendo gerado anteriormente. Nesse primeiro momento identificamos um problema em classificar adequadamente aquele paciente que possuía chagas, pois o agente causador da Doença de Chagas e leishmaniose tem uma enorme semelhança filogenética entre eles, sendo assim agrupamos os pacientes positivos para chagas como negativo para leishmaniose.

Na busca por processos que visassem o aprimoramento e viabilidade das variáveis presentes na rede neural desenvolvida, utilizamos um algoritmo capaz de otimizar a obtenção dos parâmetros presentes nas camadas de ativação, tamanho do lote, quantidade de épocas, função de erro, quantidades de neurônios e função de otimização. Este algoritmo é capaz de

testar todas as combinações possíveis para encontrar o melhor modelo de rede neural (Figura 8) para a aplicação almejada neste estudo.


Figura 8 - Fluxograma demonstrando as melhores combinações de parâmetros encontradas frente aos voltamogramas apresentados para o diagnóstico da enfermidade



Fonte: Do Autor, 2022

O modelo de função GridSearchCV (Figura 8) é um fluxo de testes que apresenta objetivos de identificar os melhores parâmetros para o problema proposto na detecção de leishmaniose, e assim, otimizar as pesquisas durante a fase de experimentação. O resultado gerado (Figura 9) desta grade de otimização de parâmetros demonstra os melhores padrões baseados na função utilizada.

Figura 9 - Resultado gerado pelo algoritmo durante o processo de otimização dos parâmetros alvos para o grafite e grafeno.



Fonte: Do Autor, 2022

O próximo passo é a Mineração de Dados onde foi utilizada a biblioteca TensorFlow em Python com funções para o modelo de Classificação que tem como objetivo identificar qual categoria aquele grupo de dados pertence. A rede neural é composta por uma camada de entrada com 14 neurônios que foram citadas na etapa três do KDD, duas camadas ocultas com 50 neurônios cada uma e uma camada de saída composta por um único neurônio. No projeto classificamos os dados da etapa de seleção como positivo para leishmaniose ou negativo para leishmaniose.

A última etapa é chamada de validação de resultados em que foram separados em 12 pacientes para treinamento e 8 pacientes para a fase de testes no eletrodo de grafite eletrodepositado com ouro e 22 pacientes para treinamento e 15 pacientes para testes nos eletrodos de grafeno. Durante a fase de treinamento obtivemos 100% de acurácia e durante a nossa fase de testes alcançamos 80% para o eletrodo de grafite eletrodepositado com ouro e 95% para o eletrodo de grafeno eletrodepositado com ouro.

6.3 Biossensores eletroquímicos

As amostras referentes as respostas experimentais das análises eletroquímicas dos experimentos foram cedidas pela Professora Dra. Renata Pereira Alves Balvedi, do Programa de Pós-Graduação em Ciências Fisiológicas da Universidade Federal do Triângulo Mineiro -

UFTM, Uberaba. Os experimentos eletroquímicos foram realizados pelo equipamento Em Stat 1 (PalmSens BV, The Netherlands) por voltametrias cíclicas (CV), e, os eletrodos selecionados foram os de grafite impressos comerciais modelo DPR-110 (Oviedo, Astúrias, Espanha) quimicamente modificados com a eletrodeposição de ouro. Os voltamogramas cíclicos analisados neste trabalho, são referentes às detecções de pacientes sintomáticos para a doença de leishmaniose visceral humana e doença de chagas em metodologia descrita anteriormente por Martins et al., 2020.

7 RESULTADOS & DISCUSSÃO

O uso de sistemas diagnósticos acoplados às tecnologias para avaliação de diagnósticos e prognósticos dos pacientes é uma técnica em ascensão (LOBO, 2017). As redes neurais representam avanços tecnológicos relevantes para auxiliar na melhor performance diagnóstica de instrumentos médicos complexos, robustos e estáticos (GUARIZI; OLIVEIRA, 2014; LOBO, 2018).

Os dados referentes ao diagnóstico dos pacientes foram cedidos pela Professora Doutora Renata Pereira Alves. Nesta primeira análise diagnóstica, características biológicas relacionadas ao sexo, etnia e idade não foram consideradas. Assim, para a escolha de pacientes alvo de detecção, considerou-se a positividade ou não das amostras frente a testes comerciais e diagnósticos padrão ouro de análise.

Dessa forma, os pacientes utilizados por esta rede neural foram separados em dois grupos de análise, sendo eles, pacientes positivos (portadores sintomáticos de Leishmaniose Visceral Humana - LVH) e pacientes negativos (portadores de sintomáticos de Doença de Chagas - DC e negativos para Leishmaniose Visceral Humana - LVH). Além do mais, avaliações acerca dos materiais utilizados e suas relações com a melhora na detecção de pacientes foram realizadas. Esses resultados foram anteriormente confrontados em outras técnicas diagnósticas e a reatividade cruzada entre doenças foi considerada para construção de uma rede neural que apresentasse eficiência diagnóstica.

Em perspectivas diagnósticas, os biossensores eletroquímicos apresentam excelente custo-benefício frente às plataformas diagnósticas convencionais como Enzyme-linked Immunosorbent Assay (ELISAs) e Polymerase Chain Reaction (PCRs). De modo que, a possibilidade de miniaturização dos dispositivos de análise eletroquímica é mais palpável e vai de encontro a demandas de portabilidade e facilidade de análises diagnósticas atuais (JUSTINO, 2013; ERBERELI, 2016; CUI, 2020).

O desenvolvimento de softwares que visam aprimoramento de análise e facilitação em leituras diagnósticas se faz necessário para melhorar a acessibilidade dos dispositivos presentes no mercado para análises de doenças. Essas redes podem facilitar leituras, acessibilidade a locais remotos do país, além de aprimorar tempos de leitura e liberação de resultados. Desta forma, com o auxílio dessas ferramentas é possível prever melhores materiais para a construção destes dispositivos, além de fornecer agilidade e portabilidade.

Nesta ótica, dentre os exemplos de biossensores utilizando o desenvolvimento de hardwares e softwares que facilitam diagnósticos e aprimoraram a experiência médico--laboratório-paciente, o caso mais bem sucedido da atualidade, está o glicosímetro. Esse desenvolvimento tornou os dispositivos para a detecção desta enfermidade mais portáteis e acessíveis para a população que necessita cotidianamente deste diagnóstico. O aprimoramento de métodos que sejam eficientes no diagnóstico e na detecção precoce de doenças é uma tendência na área médica geral (HAICK, 2021).

Mas, a viabilidade de portabilidade desses dispositivos, por vezes, estão atreladas à aquisição de equipamentos com alto custo financeiro e contratação de pessoal especializado (RAJI, 2021). Desta forma, o desenvolvimento de mecanismos, à exemplo softwares e hardwares, que auxiliem nessa questão é uma demanda contemporânea (CUI, 2020). No processo de execução, a Inteligência Artificial permite facilitar mecanismos anteriormente realizados exclusivamente por humanos especialistas, e, conseqüentemente, gerar melhoria de custo-benefício para os sistemas nacionais de saúde.

As redes neurais são treinadas matematicamente a partir de padrões de reconhecimento para interpretar resultados das demandas cotidianas que lhes foram solicitadas. Com tal característica, os sistemas acoplados à Inteligência Artificial, tendem a possuir menores índices de imprecisões relacionadas à fatores inerentes aos seres humanos (RAJI, 2021).

Essa vantagem, faz com que investimentos relacionados a esta área, dentre elas essa pesquisa, estejam obtidos resultados promissores. Neste contexto, este trabalho apresenta uma metodologia de criação de softwares para aprimoramento de leituras através de uma Inteligência Artificial (IA), que auxilia no processo de popularização de procedimentos diagnósticos para os sistemas de saúde onde essas enfermidades são preeminentes. Em saúde, os recursos oferecidos por esta tecnologia são capazes de oferecer diagnósticos mais precisos e palpáveis, fazer reconhecimentos de padrões e prever resultados a curto e longo prazo, mas essas funcionalidades ainda são pouco exploradas (RODRIGUES, 2021).

A Inteligência Artificial desenvolvida possui 14 neurônios em sua camada de entrada, agrupados para as características relacionadas às sondas de leitura eletroanalítica e de obtenção de resultados para as biomoléculas analisadas. Já a camada de saída foi constituída por 1 neurônio com função de ativação sigmóide para representações referentes à presença ou ausência de positividade da doença no paciente analisado.

As duas camadas escondidas portavam 50 neurônios cada, utilizando o material de grafite e de grafeno, quantidade revelada como necessária no decorrer da realização dos testes de desenvolvimento. Como taxa de aprendizagem, foi utilizado o otimizador Adam com taxa de aprendizagem 0.001, demandando 200 épocas para a conclusão do projeto. Assim, o reconhecimento acontece quando os valores são superiores a 0,5 e não reconhecimento acontece quando o limiar não é atingido.

Por este ângulo, os biossensores eletroquímicos que são construídos com o acoplamento de redes neurais, tendem a apresentarem maior acurácia e possibilidade de aplicação mercadológica (JIN, 2020). Neste trabalho, uma matriz de confusão (Figura 10) foi gerada para avaliar e exibir os resultados provenientes da rede neural. Diante do desenvolvimento deste método obtivemos uma proporção relevante, de modo que, ao ser desafiada com 4 pacientes negativos para a leishmaniose, o método é capaz de acertar o diagnóstico de 3 pacientes. Já quando esse mesmo método é desafiado com dados de 3 pacientes portadores da enfermidade ele foi capaz de acertar todos os resultados. Em termos práticos, isso representa uma acurácia média de 80% (Figura 10) para os dados propostos no desafio.

Figura 10 - Matriz de análise para o diagnóstico da enfermidade

		Classe Atual	
		Leishmaniose	Negativo Leishmaniose
Classe Prevista	Positivo	3 Acertos positivos	0 Falso positivos
	Negativo	1 Falso negativos	3 Acertos negativos

Fonte: Do Autor, 2022

Já utilizando o material de grafeno no desenvolvimento deste método obtivemos uma melhora relevante na acurácia, de modo que, ao ser desafiada com 6 pacientes negativos para a leishmaniose, o método é capaz de acertar o diagnóstico de 5 pacientes. Já quando esse mesmo método é desafiado com dados de 9 pacientes portadores da enfermidade ele foi capaz de acertar todos os resultados. Em termos práticos, isso representa uma acurácia média de 95% (Figura

11) para os dados propostos no desafio e comparada à dados da literatura, podemos observar que estes índices são capazes de demonstrar eficiência ao método elaborado (ALOM, 2020).

Figura 11 -Matriz de análise para o diagnóstico da enfermidade

		Classe Atual	
		Leishmaniose	Negativo Leishmaniose
Classe Prevista	Positivo	9 Acertos positivos	0 Falso positivos
	Negativo	1 Falso negativos	5 Acertos negativos

Fonte: Do Autor, 2022

Os resultados aqui apresentados corroboram com a literatura, uma vez que, em estudos envolvendo grafeno, pode-se observar propriedades importantes para os sistemas eletroquímicos, tais como, alta resistência mecânica, boa mobilidade eletrônica, flexibilidade inerte, elevada condutividade térmica e maior área superficial quando comparado ao grafite (SEGUNDO, 2016). Esses materiais, quando acoplados ao ouro, aumentam a área superficial e permitem mais acoplamentos orientados para algumas biomoléculas em eletrodos, o que conseqüentemente, aumenta a janela de detecção desses dispositivos (MARTINS *et al.*, 2020; WANG *et al.*, 2017; CORDEIRO *et al.*, 2019). Mas, as características dessas estruturas são variáveis de acordo com o tamanho, composição, e assim, a avaliação ainda representa desafios importantes para a construção de diagnósticos dependentes dessas estruturas (RIBEIRO *et al.*, 2010).


As predições acerca dessas associações benéficas podem ser realizadas com auxílio de Inteligência Artificial (BAUM, 2020). Assim, a criação desta metodologia possibilitou a melhoria na experiência de leitura e interpretação de dados provenientes de pacientes testados, além de auxiliar em estudos referentes aos materiais envolvidos na melhor escolha diagnóstica. Além do mais, os dados analisados apresentaram resultados denominados positivos ou negativos que são mais palpáveis do que os voltamogramas gerados por sistemas específicos para biossensores eletroquímicos.

A proposta de neurônios artificiais de McCulloch e Pitts que utilizam um combinador linear e funções de ativação para a construção da arquitetura de trabalho, modelo este, que é semelhante ao aplicado nesta pesquisa. As funções de ativação irão determinar a potência de saída dos sinais nos neurônios, assim, as quantidades utilizadas para o desenvolvimento do trabalho podem variar de acordo com a demanda (CORTIVO, 2010). Por este ângulo, utilizamos como funções de ativação a ReLu em camadas intermediárias da rede neural e a sigmóide em camadas de saída, uma vez que, esta combinação oferece melhores desempenhos para demanda de trabalho.

Os sinais output, nos neurônios das camadas de saída, são gerados através da propagação de informações na rede neural. O fim da propagação é marcado pelo acionamento da função métrica de erro, de modo que, o cálculo e ajuste de parâmetros dos neurônios ajudam no processo de construção dos resultados com baixo índice de erros na rede neural.


Em figuras de estimativas, durante a fase de testes da Inteligência Artificial um gráfico de métricas que envolvem três parâmetros foi gerado para avaliar o rigor do método. Neste gráfico, valores na coloração azul próximos de zero no “eixo y” indicam maior eficiência da rede neural para lidar com problemas cotidianos do mundo real. Já os valores nas cores laranja e verde representam o quanto a rede neural foi capaz de aprender durante suas respectivas fases de treinamento e testes. As métricas de acurácia, indicam a exatidão da ferramenta criada, de modo que, resultados próximos de 1 no “eixo y” indicam maior índice de acertos no processo de criação do modelo de treinamento. Assim, esses resultados sugerem uma otimização da rede neural nos processos de assertividade para as detecções propostas.

Gráfico 1 - Gráfico de avaliação das métricas de Inteligência Artificial utilizando grafite



Fonte: Elaborada pelo Autor, 2023.

Gráfico 2 - Gráfico de avaliação das métricas de Inteligência Artificial utilizando grafeno.



Fonte: Elaborada pelo Autor, 2022

Assim, os índices de acurácia obtidos neste trabalho demonstram que a rede neural desenvolvida apresenta valores promissores. Posto que, durante o treinamento, este modelo apresenta acurácia de 100% e em fases de testes a acurácia alcançou 80% no material de grafite e 95% no material de grafeno, e desta forma, este desenvolvimento poderá contribuir para a futura portabilidade do diagnóstico proposto.

Aplicamos uma técnica de validação cruzada para avaliar como o modelo se comporta diante de variações no conjunto de treinamento e de testes, isso ajuda a evitar problemas de influência da divisão de dados na métrica de acurácia. Na validação cruzada, o nosso conjunto de dados foi dividido aleatoriamente em 10 grupos, esse valor foi escolhido pois em testes empíricos mostram que os valores 5 e 10 não causam erros de testes altos nem de bias e nem de variância.

O conjunto de dados dividido em 10 grupos, ele foi separado para testes e enquanto os demais são utilizados para treinamento, após o treinamento é salvo o valor da métrica a ser analisada e descartamos o modelo para que o próximo grupo seja avaliado.

Após essa fase, calculamos a média aritmética dos valores que salvamos de acurácia em cada teste, assim comprovamos o valor de 95% para grafeno e de 80% para o grafite. Calculamos a consistência do modelo entre as iterações para avaliar a variância através do desvio padrão e foi constatado um valor de 0.09 para grafeno e de 0.24 para o grafite.

Nesta metodologia que busca o aprimoramento de detecção de pacientes positivos, os resultados de cada indivíduo ficam armazenados no sistema criado. Assim, como a positividade dessa doença tropical negligenciada (DTNs) não depende diretamente de oscilações relacionadas a cascatas bioquímicas e nível de nutrição do paciente, variações de resultados não serão observadas em um curto período de tempo caso o paciente não seja tratado. Em linhas gerais, o paciente positivo não precisa ser exposto à testagens cotidianas para verificação de índices de enfermidade e a disponibilidade de resultados possibilita que diferentes profissionais de saúde tenham ciência do estado de saúde do enfermo.

8 CONCLUSÃO

Os avanços tecnológicos aplicados à área médica estão aumentando de forma significativa a melhoria no que diz respeito a diagnósticos e tratamentos de doenças presentes na humanidade (ABOU ARABI, 2020). Os resultados, aqui discutidos, demonstram que as técnicas aplicadas na criação da rede neural para aperfeiçoamento do sensor foram bastante benéficas.

As soluções portáteis podem facilitar os diagnósticos em regiões mais remotas do mundo, uma vez que, equipamentos baseados em biossensores e com interfaces de redes neurais artificiais (RNAs) são capazes de reduzir o tempo de execução dos testes e gerar excelentes custo-benefício para o Sistema Único de Saúde Nacional (SUS). Além do mais, com a criação dessa metodologia, evitamos o aumento nos custos de produção de aparelhos de leitura dos dados gerados pelo biossensor.

Assim, os resultados obtidos mostram que o acoplamento de inteligência ao biossensor desenvolvido, pode apresentar um passo bastante promissor, onde foi possível comparar os materiais alvos das plataformas, onde foi alcançada uma faixa de detecção de 80% e 95% respectivamente durante os testes e treinamentos para detecção de leishmaniose através das amostras coletadas. No futuro podemos aprimorar esta plataforma, ensinando o modelo treinado para leishmaniose a detectar também doença de chagas para que possamos alcançar um ecossistema de detecção multiplex avançado, com bom custo-benefício é preciso para a realidade vivenciada por essas enfermidades.

REFERÊNCIAS

- ABADI, Martín *et al.* {TensorFlow}: a system for {Large-Scale} machine learning. In: USENIX SYMPOSIUM ON OPERATING SYSTEMS DESIGN AND IMPLEMENTATION (OSDI 16), 12., 2016. **Proceedings [...]**. [S.]: OSDI'16, 2016. p. 265-283.
- ABOU ARABI, Samira Alves. Aplicação da Inteligência Artificial nas indústrias farmacêuticas. 2020. Tese (Doutorado) - Universidade de São Paulo. **ACS nano**, v. 15, n. 3, p. 3557-3567, 2021.
- ALENEZI, Fayadh; ARMGHAN, Ammar; POLAT, Kemal. Wavelet transform based deep residual neural network and ReLu based Extreme Learning Machine for skin lesion classification. **Expert Systems with Applications**, v. 213, p. 119064, 2023.
- ALOM, Md Zahangir *et al.* COVID_MNet: COVID-19 detection with multi-task deep learning approaches. **arXiv preprint arXiv:2004.03747**, 2020.
- ARAÚJO, Aline Moura. **Classificação e detecção de pessoas em ambientes não controlados utilizando redes neurais convolucionais**. 2019. Trabalho de conclusão de curso (Graduação em Ciência da Computação) - Universidade Federal da Paraíba, 2019.
- ARRESTEGUI, Luis Barrera. Fundamentos históricos y filosóficos de la inteligencia artificial. **UCV-HACER. Revista de Investigación y Cultura**, v. 1, n. 1, p. 87-92, 2012.
- BAIO, José Augusto Fragale; RAMOS, Luiz Antônio; CAVALHEIRO, Éder Tadeu Gomes. Construção de eletrodo de grafite retirado de pilha comum: aplicações didáticas. **Química Nova**, v. 37, n. 6, p. 1078-1084, 2014.
- BARRETO, Renan Gomes et al. Utilizando Redes Neurais Artificiais para o Diagnóstico de Câncer Cervical. **Revista Saúde & Ciência Online**, v. 7, n. 2, p. 59-67, 2018.
- BARROS, Vinícius José Gomes Formiga et al. Biossensores eletroquímicos em tiras de aço inoxidável com deposição de antimônio para detecção de ureia. **Conjecturas**, v. 22, n. 11, p. 251-260, 2022.
- BAUM, Fabio. **Otimização de propriedades físicas de pontos quânticos e nanopartículas de semicondutores por Inteligência Artificial e planejamento experimental**. 2020. Tese (Doutorado do Programa de Pós-Graduação em Ciência dos Materiais) - Universidade Federal do Rio Grande do Sul, Instituto de Química, Porto Alegre, 2020.
- BEZERRA, Eduardo. Introdução à aprendizagem profunda. In: SIMPOSIO BRASILEIRO DE BANCO DE DADOS, 31., 2016. **Anais [...]**. 2016.
- BONAMIGO, Victoria Grassi; CARVALHO, Deborah Ribeiro; CUBAS, Marcia Regina. Método qualitativo potencializado pela Inteligência Artificial: relato de experiência. **New Trends in Qualitative Research**, v. 3, p. 105-115, 2020.
- BRAGA, Ana Vitória *et al.* Machine learning: O Uso da Inteligência Artificial na Medicina. **Brazilian Journal of Development**, v. 5, n. 9, p. 16407-16413, 2019.
- BRAININA, Kh Z. Advances in voltammetry. **Talanta**, v. 34, n. 1, p. 41-50, 1987.
- CAPUCHINHO, F. F. **Deep Learning para estimativa na escala mensal das temperaturas do ar para a região Centro-oeste do Brasil**. 2021. 90 f. Dissertação (Mestrado em Engenharia Agrícola) - Câmpus Central - Sede: Anápolis - CET, Universidade Estadual de Goiás, Anápolis-GO, 2021.

CARIDADE, Carla Isabel Madaleno Gouveia Branco. **Eléctrodos de filme de carbono: caracterização e aplicação em sensores e biossensores electroquímicos**. 2008. Tese de Doutorado. Universidade de Coimbra (Portugal).

CARRION, Patrícia; QUARESMA, Manuela. Internet da Coisas (IoT): Definições e aplicabilidade aos usuários finais. **Human Factors in Design**, v. 8, n. 15, p. 49-66, 2019.

CARVALHO, André CARLOS Ponce de Leon et al. Inteligência Artificial: riscos, benefícios e uso responsável. **Estudos Avançados**, v. 35, p. 21-36, 2021.

CHEN, Yinpeng *et al.* ReLu dinâmico. *In*: CONFERÊNCIA EUROPEIA SOBRE VISÃO COMPUTACIONAL. Springer, Cham, 2020. p. 351-367.

CHEVITARESE, Daniel Salles. **ANNCOM–Biblioteca de Redes Neurais Artificiais para Alto Desempenho Utilizando Placas de Vídeo**. 2010. Tese de Doutorado. PUC-Rio.

CHUERUBIM, Maria Ligia; SILVA, Irineu da. Possibilidades em Inteligência Artificial na detecção de padrões e previsão de acidentes em rodovias. 2019.

CHURPEK, Matthew M. *et al.* Multicenter comparison of machine learning methods and conventional regression for predicting clinical deterioration on the wards. **Critical care medicine**, v. 44, n. 2, p. 368, 2016.

COELHO, Akeni Lobo *et al.* A utilização de tecnologias da informação em saúde para o enfrentamento da pandemia do Covid-19 no Brasil. **Cadernos Ibero-Americanos de Direito Sanitário**, v. 9, n. 3, p. 183-199, 2020.

CORDEIRO, T. A. R.; GONÇALVES, M. V. C.; FRANCO, D.L.; REIS, A.B.; MARTINS, H.R. Label-free electrochemical impedance immunosensor based on modified screen-printed gold electrodes for the diagnosis of canine visceral leishmaniasis. **Talanta**, v. 195, p. 327-332, 2019.

CORTIVO, Fábio Dall *et al.* Estimativa do albedo de espalhamento simples usando uma rede neural de múltiplas camadas. *In*: CNMAC, 23., 2010. [Anais...]. 2010.

COUTO, Giselle Giovanna do. **Nanopartículas de níquel: síntese, caracterização, propriedades e estudo de sua utilização como catalisadores na obtenção de nanotubos de carbono**. 2006. Dissertação (Mestrado do Programa de Pós-Graduação em Química) - Universidade Federal do Paraná, Curitiba, 2006.

COZMAN, Fabio G.; PLONSKI, Guilherme Ary; NERI, Hugo (org.). **Inteligência Artificial: Avanços e Tendências**. São Paulo: Instituto de Estudos Avançados, 2021.

COZMAN, Fabio Gagliardi. No canal da Inteligência Artificial-Nova temporada de desgrehados e empertigados. **Estudos Avançados**, v. 35, p. 7-20, 2021.

CUI, Feiyun *et al.* Advancing biosensors with machine learning. **ACS sensors**, v. 5, n. 11, p. 3346-3364, 2020.

CYSNEIROS, Paulo Gileno; PAPERT, Seymour M.; DAS CRIANÇAS, A. Máquina. Resenha Crítica. **Revista Brasileira de Informática na Educação**, n. 5, 1999.

DENG, C.; JI, X.; RAINEY, C.; ZHANG, J.; LU, W. Integrating machine learning with human knowledge. **Isience**, v. 23, n. 11, 101656.

DENG, L.; YU, D. Deep learning: methods and applications. **Foundations and trends® in signal processing**, v. 7, n. 3-4, p. 197-387, 2014.

DESAI, Meha; SHAH, Manan. An anatomization on breast cancer detection and diagnosis employing multi-layer *Perceptron* neural network (MLP) and Convolutional neural network (CNN). **Clinical eHealth**, v. 4, p. 1-11, 2021.

DÍAZ, O. *et al.* ¿ Son los sistemas de inteligencia artificial una herramienta útil para los programas de cribado de cáncer de mama?. **Radiología**, v. 63, n. 3, p. 236-244, 2021.

EL NAQA, Issam; MURPHY, Martin J. What is machine learning?. **Machine Learning in Radiation Oncology**, Springer, p. 3-11, Cham, 2015.

ELGRISHI, Noémie *et al.* A practical beginner's guide to cyclic voltammetry. **Journal of Chemical Education**, v. 95, n. 2, p. 197-206, 2018.

ERBERELI, Camila Regina. **Desenvolvimento de um imunossensor descartável para o diagnóstico precoce da doença de Alzheimer**. 2016. Dissertação (Mestrado em Química) – Universidade Federal de São Carlos, São Carlos, 2016.

FARAHMAND, Shervin *et al.* Artificial intelligence-based triage for patients with acute abdominal pain in emergency department; a diagnostic accuracy study. **Advanced Journal of Emergency Medicine**, v. 1, n. 1, 2017.

FAYYAD, Usama; PIATETSKY-SHAPIO, Gregory; SMYTH, Padhraic. From data mining to knowledge discovery in databases. **AI magazine**, v. 17, n. 3, p. 37-37, 1996.

FERREIRA, L. F. Sem rótulos de impedância eletroquímica imunossensor baseado em eletrodos de ouro impressos em tela modificadas para o diagnóstico de leishmaniose visceral canina. **Talanta**, 195, 327-332, 2019.

FERREIRA, Renan Williams Marques. **A Inteligência Artificial na Identificação de Espécies de Candida**. Dissertação (Mestrado). Universidade Federal de Pernambuco, 2020.

FREITAS, Neli Klix. Desenvolvimento humano, organização funcional do cérebro e aprendizagem no pensamento de Luria e de Vygotsky. **Ciências & Cognição**, v. 9, p. 91-96, 2006.

GALLI, Andressa *et al.* Electroanalytical techniques for the determination of pesticides in foods. **Química nova**, v. 29, p. 105-112, 2006.

GODOI, Maiko Gustavo de; ARAÚJO, Liriane Soares. A Internet das Coisas: evolução, impactos e benefícios. **Revista interface tecnológica**, v. 16, n. 1, p. 19-30, 2019.

GOMES, D. dos S. Inteligência Artificial: conceitos e aplicações. **Olhar Científico**, v. 1, n. 2, p. 234-246, 2010.

GOMES, Dennis dos Santos. Inteligência Artificial: conceitos e aplicações. **Olhar Científico**, v. 1, n. 2, p. 234-246, 2011.

GONZÁLEZ BENÍTEZ, Neilys; ESTRADA SENTÍ, Vivian; FEBLES ESTRADA, Aylin. Estudio y selección de las técnicas de Inteligencia Artificial para el diagnóstico de enfermedades. **Revista de Ciencias Médicas de Pinar del Río**, v. 22, n. 3, p. 131-141, 2018.

GUARIZI, Débora Deflim; OLIVEIRA, Eliane Vendramini. Estudo da Inteligência Artificial aplicada na área da saúde. In: COLLOQUIUM EXACTARUM, 2014. **Anais [...]**. 2014. 26-37.

HAICK, Hossam; TANG, Ning. Artificial intelligence in medical sensors for clinical decisions.

HAUCK, Tanya S. *et al.* Nanotechnology diagnostics for infectious diseases prevalent in

developing countries. **Advanced drug delivery reviews**, v. 62, n. 4-5, p. 438-448, 2010.

JACINTHO, Fernanda dos S. Becker; PENHA, Alice Demaria Silva. Interfaces conversacionais: análise de tarefas para siri e Google Now. **Ergodesign & HCI**, v. 4, n. 2, p. 72-81, 2016.

JAIN, Anubhav; PERSON, Kristin A.; CEDER, Gerbrand. Atualização de pesquisa: A iniciativa genoma de materiais: Compartilhamento de dados e o impacto de bancos de dados colaborativos ab initio. **Materiais APL**, v. 4, n. 5, p. 053102, 2016.

JERONYMO, Victor. **Implementando métodos de otimização para treinamento de redes neurais com pytorch**. 2019. Monografia (oInstituto de Matemática, Estatística e Computação Científica) - Universidade Estadual de Campinas, 2019.

JHA, K.; DOSHI, A.; PATEL, P.; SHAH, M. A comprehensive review on automation in agriculture using artificial intelligence. **Artificial Intelligence in Agriculture**, v. 2, p. 1-12, 2019.

JIN, Xiaofeng *et al.* Artificial intelligence biosensors: Challenges and prospects. **Biosensors and Bioelectronics**, v. 165, p. 112412, 2020.

JUSTINO, Celine IL; ROCHA-SANTOS, Teresa AP; DUARTE, Armando C. Biossensores com nanotubos de carbono para aplicações clínicas: avanços tecnológicos. **Revista Captar: Ciência e Ambiente para Todos**, v. 4, n. 1, p. 1-12, 2013.

KACUTA, Stephanie Luri. **Utilização da metodologia KDD para descoberta de conhecimento em dados relacionados a toxicodependência e ideação suicida**. 2021. Trabalho de Conclusão de Curso (Bacharelado em Engenharia de Produção) - Universidade Tecnológica Federal do Paraná, Londrina, 2021.

KAIESKI, Naira *et al.* Application of artificial intelligence methods in vital signs analysis of hospitalized patients: A systematic literature review. **Applied Soft Computing**, v. 96, p. 106612, 2020.

KALMET, Pishtiwan HS *et al.* Deep learning in fracture detection: a narrative review. **Acta orthopaedica**, v. 91, n. 2, p. 215-220, 2020.

KARNICK, Harish. 1. Introduction Of languages that are still alive LISP is the second old-est. It was created by John McCarthy in 1958 [1], one year after John Backus created FORTRAN. The two languages are very different in conception, design, ap. **RESONANCE**, 2014.

KAUFMAN, Dora. Inteligência Artificial: repensando a mediação. **Brazilian Journal of Development**, v. 6, n. 9, p. 66742-66760, 2020.

KAUSHIK, Ajeet Kumar *et al.* Electrochemical SARS-CoV-2 sensing at point-of-care and artificial intelligence for intelligent COVID-19 management. **ACS Applied Bio Materials**, v. 3, n. 11, p. 7306-7325, 2020.

KHAN, M. Z. H. Nanoparticles modified ITO based biosensor. **Journal of Electronic Materials**, v. 46, n. 4, p. 2254-2268, 2017.

LAL, Amos *et al.* Artificial intelligence and computer simulation models in critical illness. **World Journal of Critical Care Medicine**, v. 9, n. 2, p. 13, 2020.

LI, Lin *et al.* Using artificial intelligence to detect COVID-19 and community-acquired pneumonia based on pulmonary CT: evaluation of the diagnostic accuracy. **Radiology**, v. 296, n. 2, p. E65-E71, 2020.

LIMA, Bruno Cesar dos Santos *et al.* Projeto de Links de Fibras Ópticas Usando Técnicas de Inteligência Artificial. **WWW/INTERNET**, p. 94, 2019.

LOBO, Luiz Carlos. Inteligência Artificial e medicina. **Revista Brasileira de Educação Médica**, v. 41, n. 2, p. 185-193, 2017.

LOBO, Luiz Carlos. Inteligência Artificial, o Futuro da Medicina e a Educação Médica. **Revista Brasileira de Educação Médica**, v. 42, p. 3-8, 2018.

LOGUERCIO, Lara Fernandes. **Biossensor enzimático eletroquímico para detecção do pesticida carbaril utilizando filme funcional de polipirrol**. 2019. Tese (Química) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2019.

LORETO, Melina; LISBOA, Thiago; MOREIRA, Viviane P. Early prediction of ICU readmissions using classification algorithms. **Computers in biology and medicine**, v. 118, p. 103636, 2020.

LU, Lu; YEONJONG Shin; YANHUI Su; GEORGE Karniadakis. Dying ReLu e inicialização: Teoria e exemplos numéricos. **arXiv preprint arXiv:1903.06733**, 2019.

LUGO-REYES, Saúl Oswaldo; MALDONADO-COLÍN, Guadalupe; MURATA, Chiharu. Inteligencia artificial para asistir el diagnóstico clínico en medicina. **Revista Alergia México**, v. 61, n. 2, p. 110-120, 2014.

MAIMON, Oded; ROKACH, Lior. Decomposition methodology for knowledge discovery and data mining. **Data mining and knowledge discovery handbook**. Springer, Boston, MA, p. 981-1003, 2005.

MAIMON, Oded; ROKACH, Lior. Introduction to knowledge discovery and data mining. **Data mining and knowledge discovery handbook**. Springer, Boston, MA, p. 1-15, 2009.

MANICKAM, Pandiaraj *et al.* Artificial intelligence (AI) and internet of medical things (IoMT) assisted biomedical systems for intelligent healthcare. **Biosensors**, v. 12, n. 8, p. 562, 2022.

MARQUES, Bartolomeu das Neves; ARAÚJO, Kauanna Soares; TELES, Eduardo Oliveira. Os reflexos da inteligência artificial na propriedade intelectual. **Scientia: Revista Científica Multidisciplinar**, v. 5, n. 2, p. 69-83, 2020.

MARTINS, Beatriz R. *et al.* Development of an electrochemical immunosensor for specific detection of visceral leishmaniasis using gold-modified screen-printed carbon electrodes. **Biosensors**, v. 10, n. 8, p. 81, 2020.

MASSUCATTO, J, D, P. **Aplicação de conceitos de redes neurais convolucionais na classificação de imagens de folhas**. 2018. Trabalho de Conclusão de Curso 1. Curso de Engenharia de Computação da Universidade Tecnológica Federal do Paraná - UTFPR, Câmpus Pato Branco. 2018. Disponível em: http://repositorio.roca.utfpr.edu.br/jspui/bitstream/1/11013/1/PB_COENC_2018_1_03.pdf. Acesso em: 17 nov. 2021.

MATUSCHEK, Louis; GÖBEL, Gero; LISDAT, Fred. Electrochemical detection of serotonin in the presence of 5-hydroxyindoleacetic acid and ascorbic acid by use of 3D ITO electrodes. **Electrochemistry Communications**, v. 81, p. 145-149, 2017.

MENDONÇA, A. de *et al.* Inteligência Artificial–recursos humanos frente as novas tecnologias, posturas e atribuições. **Revista Contribuciones a la Economía**, v. 16968360, 2018.

MESQUITA, Claudio Tinoco. Inteligência Artificial e Machine Learning em Cardiologia-Uma Mudança de Paradigma. **International Journal of Cardiovascular Sciences**, v. 30, p. 187-188, 2017.

MITZALA, Athanasia *et al.* Artificial intelligence in colorectal cancer screening, diagnosis and treatment. A new era. **Current Oncology**, v. 28, n. 3, p. 1581-1607, 2021.

MOREIRA, P. S. da C.; SALERNO, B. N.; TSUNODA, D. F. Internet das coisas e aprendizado de máquina na área da saúde: uma análise bibliométrica da produção científica de 2009 a 2019. **Revista Eletrônica de Comunicação, Informação & Inovação em Saúde**, [S.l.], v. 14, n. 1, 2020. DOI: 10.29397/reciis.v14i1.1807. Disponível em: <https://www.reciis.iciet.fiocruz.br/index.php/reciis/article/view/1807>. Acesso em: 21 jun. 2023.

NASCIMENTO, Jônatas C. **Redes Neurais Artificiais em jogos digitais**. 2021. TCC (Faculdade de Computação e Informática) – Mackenzie, 2021.

NASCIMENTO, Renan *et al.* Soluções de Aprendizado de Máquina para Estimar em Tempo Real a Pose Humana em Aplicações de Saúde. **Sociedade Brasileira de Computação**, 2020.

NIELSEN, Michael. Neural Networks and Deep Learning: Perceptron. **Architecture, Algorithms**, 2019.

NWANKPA, Chigozie *et al.* Activation functions: Comparison of trends in practice and research for deep learning. **arXiv preprint arXiv:1811.03378**, 2018.

PACHECO, C.A.R.; PEREIRA, N.S. Deep Learning conceitos e utilização nas diversas áreas do conhecimento. **Revista Ada Lovelace**, Anápolis, v.2, p.34-49, 2018.

PACHECO, Wagner Felipe *et al.* Voltametrias: Uma breve revisão sobre os conceitos. **Revista Virtual de Química**, v. 5, n. 4, p. 516-537, 2013.

PANG, Bo; NIJKAMP, Erik; WU, Ying Nian. Deep learning with tensorflow: A review. **Journal of Educational and Behavioral Statistics**, v. 45, n. 2, p. 227-248, 2020.

PANWAR, Shailesh Singh; RAIWANI, Y. P. Data reduction techniques to analyze NSL-KDD dataset. **Int. J. Comput. Eng. Technol**, v. 5, n. 10, p. 21-31, 2014.

PAULA FILHO, Luiz Pinto de *et al.* A revolução digital na saúde: como a Inteligência Artificial e a internet das coisas tornam o cuidado mais humano, eficiente e sustentável. **Cadernos Ibero-Americanos de Direito Sanitário**, v. 9, n. 3, p. 225-234, 2020.

PENN, Sharron G.; HE, Lin; NATAN, Michael J. Nanoparticles for bioanalysis. **Current opinion in chemical biology**, v. 7, n. 5, p. 609-615, 2003.

PÉREZ-FERNÁNDEZ, Beatriz; COSTA-GARCÍA, Agustín; MUÑIZ, Alfredo de la Escosura. Electrochemical (bio) sensors for pesticides detection using screen-printed electrodes. **Biosensors**, v. 10, n. 4, p. 32, 2020.

PINGARRÓN, José M.; YAÑEZ-SEDEÑO, Paloma; GONZÁLEZ-CORTÉS, Araceli. Gold Nanoparticle-based electrochemical biosensors. **Electrochimica Acta**, v. 53, n. 19, p. 5848-5866, 2008.

POSSEBON, Gabriela. **Análise Voltamétrica Cíclica: Uma ferramenta para a análise qualitativa do mel**. [2022]. Dissertação (Mestrado em Qualidade e Segurança Alimentar da Escola Superior Agrária de Bragança) - Universidade Tecnológica Federal do Paraná, [2022].

- RAJI, Hassan *et al.* Biosensors and machine learning for enhanced detection, stratification, and classification of cells: A review. **arXiv preprint arXiv:2101.01866**, 2021.
- RAMPASEK, Ladislav; GOLDENBERG, Anna. TensorFlow: biology's gateway to deep learning?. **Cell systems**, v. 2, n. 1, p. 12-14, 2016.
- RIBEIRO, Athyrson Machado *et al.* Um estudo comparativo entre cinco métodos de otimização aplicados em uma rnc voltada ao diagnóstico do glaucoma. **Revista de Sistemas e Computação-RSC**, v. 10, n. 1, 2020.
- RIBEIRO, Fabio Negreiros *et al.* **Estudos teóricos das propriedades estruturais de superfícies e nanopartículas metálicas**. 2010. Tese (Doutorado em ciências) – Universidade Federal de Minas Gerais, 2010.
- RIBEIRO, Maxwell da Mata; QUIMARÃES, Samuel Soares. Redes neurais utilizando tensorflow e keras. **RE3C-Revista Eletrônica Científica de Ciência da Computação**, v. 13, n. 1, 2018.
- RIZZO, Igor Vilela; CANATO, Robson Leandro Carvalho. Inteligência Artificial: funções de ativação. **Prospectus**, v. 2, n. 2, 2020.
- RODRIGUES, Joanna Pinheiro *et al.* Aplicações da IA na Saúde Humana. *In*: CONGRESSO NACIONAL UNIVERSIDADE, EAD E SOFTWARE LIVRE. 2021. **Anais [...]**. 2021.
- ROMANI, Lucas Flasch. **Aplicação de redes neurais artificiais na sugestão de investimentos**. 2017. Monografia (Graduação) - Universidade de Brasília, Brasília, 2017.
- ROQUE, Antonio. **O Perceptron de Rosenblatt: Psicologia Conexionista**. [S.l.]: Sisne, 30 out. 2016. Disponível em: <http://sisne.org/Disciplinas/PosGrad/PsicoConex/aula4.pdf>. Acesso em: 11 dez. 2019.
- ROSA, Claudia Marisa; SOUZA, Paulo Augusto Ramalho de; SILVA, Joaquim Manoel da. Inovação em saúde e internet das coisas (IoT): Um panorama do desenvolvimento científico e tecnológico. **Perspectivas em Ciência da Informação**, v. 25, p. 164-181, 2020.
- ROSÁRIO, Mychelle Senra *et al.* Doenças tropicais negligenciadas: caracterização dos indivíduos afetados e sua distribuição espacial. **Revista Brasileira de Pesquisa em Saúde/Brazilian Journal of Health Research**, v. 19, n. 3, p. 118-127, 2017.
- SANTANA, Glauciele Souza de *et al.* Diagnóstico precoce do câncer bucal com Inteligência Artificial: Uma revisão integrativa. **Research, Society and Development**, v. 10, n. 5, p. e57310513319-e57310513319, 2021.
- SANTANA, João Pedro *et al.* **Uma Ferramenta Visual para o Desenvolvimento de Modelos de Detecção de Objetos com Deep Learning no Ensino Superior**. 2022. TCC (Graduação) - Universidade Federal de Santa Catarina, 2022.
- SANTOS, Elisama *et al.* Rede Neural *Perceptron* Aplicada Ao Jogo da Nave. **Revista Computação Aplicada-UNG-Ser**, v. 8, n. 1, p. 36-41, 2019.
- SANTOS, Marcel Koenigkam *et al.* Inteligência Artificial, aprendizado de máquina, diagnóstico auxiliado por computador e radiômica: avanços da imagem rumo à medicina de precisão. **Radiologia Brasileira**, v. 52, p. 387-396, 2019.
- SANTOS, Marcel Koenigkam *et al.* Inteligência Artificial, aprendizado de máquina, diagnóstico auxiliado por computador e radiômica: avanços da imagem rumo à medicina de precisão. **Radiologia Brasileira**, v. 52, p. 387-396, 2019.

SANTOS, Paulo César Melquíades. **Desenvolvimento e caracterização de eletrodos de grafite funcionalizados com filmes de homopolímeros, copolímeros e bicamadas para uso em biossensores**. 2020. Dissertação (Mestrado em Química) – Programa de Pós-Graduação em Química, Universidade Federal dos Vales do Jequitinhonha e Mucuri, Diamantina, 2020.

SARFATI, Gilberto. Prepare-se para a revolução: Economia colaborativa e Inteligência Artificial. **GV-EXECUTIVO**, v. 15, n. 1, p. 25-28, 2016.

SCHLEDER, Gabriel R.; FAZZIO, Adalberto. Machine Learning na Física, Química, e Ciência de Materiais: Descoberta e Design de Materiais. **Revista Brasileira de Ensino de Física**, v. 43, 2021.

SEGUNDO, J. E. D. V.; VILAR, Eudésio Oliveira. Grafeno: Uma revisão sobre propriedades, mecanismos de produção e potenciais aplicações em sistemas energéticos. **Revista Eletrônica de Materiais e Processos**, v. 11, n. 2, p. 54-57, 2016.

SHANNON, C. E. Xxii. programming a computer for playing chess. **Philosophical Magazine and Journal of Science**, v. 41, n. 314, p. 256–275, 1950

SHUM, Heung-Yeung; HE, Xiao-dong; LI, Di. From Eliza to XiaoIce: challenges and opportunities with social *chatbots*. **Frontiers of Information Technology & Electronic Engineering**, v. 19, n. 1, p. 10-26, 2018.

SILVA, R, E, V. **Um estudo comparativo entre redes neurais convolucionais para a classificação de imagens**. 2018. Trabalho de Conclusão de Curso (Graduação em Sistemas de Informação) – Campus Quixadá da Universidade Federal do Ceará. 2018.

SILVA, Roberta Jerônimo da. **A Inteligência Artificial no contexto da ciência da informação: uma análise de domínio**. 2021. Dissertação (Mestrado em Ciência da Informação) – Universidade do Porto, 2021.

SILVA, Sarah Mendes da. **Detecção de zinco em fertilizantes de Estruvita por voltametria de redissolução anódica de onda quadrada utilizando um eletrodo de ouro descartável**. 2020. 57 f. Trabalho de Conclusão de Curso (Graduação em Química Industrial) – Universidade Federal de Uberlândia, Uberlândia, 2020.

SILVA, Waterloo Ferreira da *et al.* **Análise dos impactos harmônicos na qualidade da energia elétrica utilizando kdd: estudo de caso na Universidade Federal do Pará**. 2019. Dissertação (Mestrado do Programa de Pós-Graduação em Engenharia Elétrica) - Instituto de Tecnologia da Universidade Federal do Pará, 2019.

SONG, Yang *et al.* Recent advances in electrochemical biosensors based on graphene two-dimensional nanomaterials. **Biosensors and Bioelectronics**, v. 76, p. 195-212, 2016.

SOUSA, Isnaldo Isaac Barbosa. Previsão de focos de calor na região metropolitana de Maceió utilizando rede neural artificial. **Revista Brasileira de Geografia Física**, v. 15, n. 05, p. 2313-2326, 2022.

SOUZA GOMES, Elias Amadeu de. **Aplicabilidade de Algoritmos de Aprendizado de Máquina para Detecção de Intrusão e Análise de Anomalias de Rede**. 2019. Dissertação (Mestrado do Programa de Pós-Graduação em Informática) – Universidade Federal de Minas Gerais, Belo Horizonte, 2019.

SOUZA, Leonardo Henrique Oliveira de *et al.* O uso da Inteligência Artificial e de chatterbots como ferramentas de auxílio no processo de ensino-aprendizagem. In: CONGRESSO

NACIONAL – EDUCAÇÃO – Conedu, 2019. **Anais [...]**. 2019.

SRIVASTAVA, Nitish *et al.* Dropout: a simple way to prevent neural networks from overfitting. **The journal of machine learning research**, v. 15, n. 1, p. 1929-1958, 2014.

TALLURY, Padmavathy *et al.* Nanobioimaging and sensing of infectious diseases. **Advanced drug delivery reviews**, v. 62, n. 4-5, p. 424-437, 2010.

TAQI, Arwa Mohammed *et al.* The impact of multi-optimizers and data augmentation on TensorFlow convolutional neural network performance. *In: IEEE CONFERENCE ON MULTIMEDIA INFORMATION PROCESSING AND RETRIEVAL (MIPR)*. **Anais [...]**. IEEE, 2018. p. 140-145.

TAULLI, Tom. **Introdução à Inteligência Artificial: uma abordagem não técnica**. Novatec, 2020.

TEIXEIRA, Victória Cacita. **Nanotecnologia e Diagnóstico na Medicina**. Trabalho de Conclusão do Curso (Graduação em Farmácia Bioquímica da Faculdade de Ciências Farmacêuticas) - Universidade de São Paulo, 2021.

THAKKAR, Ankit; LOHIYA, Ritika. A review on machine learning and deep learning perspectives of IDS for IoT: recent updates, security issues, and challenges. **Archives of Computational Methods in Engineering**, v. 28, n. 4, p. 3211-3243, 2021.

TURNER, Anthony PF. Biosensors: sense and sensibility. **Chemical Society Reviews**, v. 42, n. 8, p. 3184-3196, 2013.

VALE, Cauê M.; ZAMBIAZI, Rui C. Previsão de estabilidade de óleos vegetais através da rede de Inteligência Artificial. **Food Science and Technology**, v. 20, p. 342-348, 2000.

VEIGA, Rui; CADETE PIRES, Cristina Maria Paulo. Percepção do impacto da Inteligência Artificial em contexto ocupacional. **ISLA Multidisciplinary e-Journal**, v. 1, n. 1, p. 47-60, 2018.

WANG, Yongzhong *et al.* Application of nanodiagnostics in point-of-care tests for infectious diseases. **International journal of nanomedicine**, v. 12, p. 4789, 2017.

WELCH, Christine M.; COMPTON, Richard G. The use of nanoparticles in electroanalysis: a review. **Analytical and bioanalytical chemistry**, v. 384, n. 3, p. 601-619, 2006.

WOLFRANN, Joice *et al.* Simulação da irrigação por aspersão utilizando redes neurais artificiais treinadas com e sem termo momentum. **Revista de Computação Aplicada ao Agronegócio**, v. 1, n. 2, p. 44-55, 2019.

XIANG, Yang *et al.* Artificial intelligence-based diagnosis of diabetes mellitus: Combining fundus photography with traditional Chinese medicine diagnostic methodology. **BioMed Research International**, v. 2021, 2021.