



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL RURAL DA AMAZÔNIA
CAMPUS CAPITÃO POÇO

ALÍCIA GRAZIELLA BALBINO MENDES
ANTONIA GENARA DE SOUSA SILVA

DIAFOOT: APLICATIVO *MOBILE* PARA AUXILIAR NA ESCOLHA DA
COBERTURA PARA LESÕES DO PÉ DIABÉTICO POR MEIO DE MODELAGEM DE
APRENDIZADO DE MÁQUINA *FEEDFORWARD*.

CAPITÃO POÇO – PA

2023

ALÍCIA GRAZIELLA BALBINO MENDES
ANTONIA GENARA DE SOUSA SILVA

***DIAFOOT*: APLICATIVO *MOBILE* PARA AUXILIAR NA ESCOLHA DA
COBERTURA PARA LESÕES DO PÉ DIABÉTICO POR MEIO DE MODELAGEM DE
APRENDIZADO DE MÁQUINA *FEEDFORWARD*.**

Trabalho de Conclusão de Curso apresentado
à Universidade Federal Rural da Amazônia –
campus Capitão Poço, como requisito básico
para a conclusão do curso de Sistemas de
Informação e obtenção do título de Bacharel.

Orientador: Prof. Dr. Carlos Alberto de
Albuquerque Silva.

CAPITÃO POÇO – PA

2023

Dados Internacionais de Catalogação na Publicação (CIP)
Bibliotecas da Universidade Federal Rural da Amazônia
Gerada automaticamente mediante os dados fornecidos pelo(a) autor(a)

- M538d Mendes, Alícia Graziella Balbino
DIAFOOT : aplicativo mobile para auxiliar na escolha da cobertura para lesões do pé diabético por meio de modelagem de aprendizado de máquina feedforward. / Alícia Graziella Balbino Mendes, Antonia Genara de Sousa Silva. - 2023.
49 f. : il. color.
- Trabalho de Conclusão de Curso (Graduação) - Curso de Sistemas de Informação, Campus Universitário de Capitão Poço, Universidade Federal Rural Da Amazônia, Capitão Poço, 2023.
Orientador: Prof. Dr. Carlos Alberto de Albuquerque Silva
1. Redes Neurais Artificiais. 2. Diabetes. 3. Pé Diabético. 4. Aplicativo Mobile. I. Silva, Carlos Alberto de Albuquerque, *orient.* II. Título
-

AGRADECIMENTOS

Primeiramente, agradeço a Deus por me permitir realizar esta jornada acadêmica, por me proporcionar oportunidades de crescimento e por me abençoar e proteger ao longo de toda a minha vida.

Gostaria também de expressar minha gratidão aos meus pais, Antônio de Araújo e Francisca Lúcia, pelo apoio incondicional, incentivo e por sempre acreditarem em mim. Agradeço também às minhas irmãs, Gerlane, Bárbara e Josilene, por terem acreditado em meu potencial e me incentivado a seguir meus sonhos.

Não poderia deixar de mencionar meus orientadores, Koiti Yasojima, Carlos Albuquerque e Evelin Cardoso, pelos quais sou extremamente grata. Também gostaria de deixar meu agradecimento especial à Samilis Brito por sua incondicional ajuda nesse trabalho e na vida. A parceria, paciência e dedicação que tiveram comigo foram essenciais para o desenvolvimento deste trabalho, contribuindo para o meu crescimento e amadurecimento acadêmico e profissional.

AGRADECIMENTOS

Em primeiro lugar, gostaria de expressar minha gratidão a Deus, pela dádiva da vida e por me permitir trilhar esta jornada acadêmica. A Ele agradeço por me abençoar e me proteger ao longo de toda a minha vida e por me proporcionar oportunidades de crescimento pessoal e profissional.

Gostaria de dedicar um agradecimento especial à minha mãe, Luciene, por todo o amor, suporte e incentivo que ela me deu ao longo de toda a minha vida e também durante a realização deste trabalho.

Também não posso deixar de agradecer meu orientador, Carlos Alberto, pela sua dedicação, paciência e conhecimento, que foram fundamentais para a realização deste trabalho. Suas orientações foram valiosas para que pudéssemos alcançar nossos objetivos.

A conclusão deste trabalho representa o fim de uma jornada árdua, porém extremamente gratificante. Gostaria de expressar meus sinceros agradecimentos a todas as pessoas que, de alguma forma, contribuíram para a realização deste estudo.

RESUMO

O pé diabético é uma das complicações mais graves do diabetes mellitus e pode levar a amputações se não for tratado adequadamente. Neste contexto, este trabalho teve como objetivo desenvolver um aplicativo móvel com uma rede neural feedforward para auxiliar no tratamento do pé diabético. Utilizamos a metodologia do Processo Unificado no desenvolvimento da pesquisa e do projeto. O aplicativo foi projetado para gerar recomendações de coberturas ideais para lesões de pé diabético, com base em um modelo de aprendizado de máquina. Os principais objetivos do trabalho foram alcançados, com a rede neural feedforward atingindo uma acurácia de 100% e o aplicativo sendo desenvolvido com uma interface simples e amigável para os profissionais da saúde. Os resultados obtidos mostraram que o aplicativo é capaz de gerar recomendações precisas e úteis para os profissionais da área da saúde. Concluimos que o aplicativo pode ser uma ferramenta valiosa no tratamento do pé diabético, melhorando a qualidade de vida dos pacientes e reduzindo o risco de amputações.

Palavras-chaves: Redes Neurais Artificiais, Pé Diabético, Aplicação Mobile.

ABSTRACT

The diabetic foot is one of the most serious complications of diabetes mellitus and can lead to amputations if not treated properly. In this context, this work aimed to develop a mobile application with a feedforward neural network to assist in the treatment of diabetic foot. We used the Unified Process methodology in the development of the research and the project. The application was designed to generate recommendations of ideal coverings for diabetic foot lesions, based on a machine learning model. The main objectives of the work were achieved, with the feedforward neural network reaching an accuracy of 100% and the application being developed with a simple and friendly interface for health professionals. The results obtained showed that the application is capable of generating accurate and useful recommendations for health professionals. We conclude that the application can be a valuable tool in the treatment of diabetic foot, improving the quality of life of patients and reducing the risk of amputations.

Keywords: Artificial Neural Networks, Diabetic Foot, Mobile Application.

LISTA DE ILUSTRAÇÕES

Figura 1 -	Classificação do <i>Diabetes Mellitus</i>	13
Figura 2 -	Neurônio Biológico.....	16
Figura 3 -	Neurônio Artificial.....	17
Quadro 1 -	Funções de ativação e seus respectivos gráficos.....	20
Figura 4 -	Rede <i>Feedforward</i> de Uma Camada.....	21
Figura 5 -	Rede <i>Feedforward</i> Multicamadas.....	22
Figura 6 -	Rede Realimentada.....	23
Figura 7 -	Aprendizagem Supervisionada.....	24
Figura 8 -	Aprendizagem Não-Supervisionada.....	24
Figura 9 -	Processo Unificado.....	29
Figura 10 -	Diagrama de caso de uso da aplicação.....	30
Figura 11 -	Arquitetura detalhada da aplicação.....	30
Figura 12 -	Prototipagem da aplicação: Captura das Características.....	31
Figura 13 -	Prototipagem da aplicação: Classificador e Interpretador.....	32
Figura 14 -	Modelagem NoSQL do banco de dados utilizado.....	33
Figura 15 -	Rede Neural FeedForward - FF.....	34
Tabela 1 -	Distribuição das camadas densas.....	37
Figura 16 -	Matriz de confusão.....	38
Figura 17 -	Telas de autenticação.....	39
Figura 18 -	Telas do paciente.....	40
Figura 19 -	Telas do paciente - Anamnese.....	40
Figura 20 -	Telas do paciente - Classificação e Interpretação.....	41
Figura 21 -	Telas do paciente - Informações.....	42

LISTA DE SIGLAS

Adam	Adaptive Moment Estimation (Estimação Adaptativa de Momentos)
API	Application Programming Interface (Interface de Programação de Aplicação)
DAP	Doença Arterial Periférica
DM	Diabetes Mellitus
DM1	Diabetes Mellitus Tipo I
DM2	Diabetes Mellitus Tipo II
DMG	Diabetes Mellitus Gestacional
FF	FeedForward
IA	Inteligencia Artificial
IDF	International Diabetes Federation (Federação Internacional de Diabetes)
IMC	Índice de Massa Corpórea
IVP	Identifiable Virtual Patient (Paciente Virtual Identificável)
JSON	JavaScript Object Notation (Notação de Objetos JavaScript)
NoSQL	Not Only SQL (Não Apenas SQL)
PU	Processo Unificado
RBF	Radial Basis Function (Função de Base Radial)
ReLU	Rectified Linear Unit (Unidade Linear Retificada)
RNA	Rede Neural Artificial
SBD	Sociedade Brasileira de Diabetes
SUS	Sistema Único de Saúde
UI/UX	User Interface / User Experience (Interface do Usuário/ Experiência do Usuário)

SUMÁRIO

1 INTRODUÇÃO.....	10
2 DIABETES.....	12
2.1 Diabetes Tipo I.....	13
2.2 Diabetes Tipo II.....	14
2.3 Pé Diabético.....	14
3 REDES NEURAIS ARTIFICIAIS.....	15
3.1 Neurônio Artificial.....	16
3.1.1 Função de Ativação.....	18
3.2 Arquitetura das Redes Neurais.....	21
3.3 Processo de Aprendizagem.....	23
4 TECNOLOGIAS EM SAÚDE.....	25
5 METODOLOGIA.....	28
5.1 Etapas do Estudo.....	29
5.1.1 Fase de Concepção.....	29
5.1.2 Fase de Elaboração.....	30
5.1.3 Fase de Construção.....	35
5.1.4 Fase de Transição.....	36
5.1.5 Atividades.....	36
6 RESULTADOS E DISCUSSÕES.....	37
6.1 Implementação da RNA Profunda.....	37
6.2 Construção do Aplicativo.....	39
7 CONCLUSÃO.....	43
REFERÊNCIAS.....	45

1 INTRODUÇÃO

A influência crescente da tecnologia na sociedade é inegável e a pandemia da SARS-CoV-2 acelerou ainda mais essa transformação. Com a necessidade do distanciamento social para conter a disseminação do vírus, a tecnologia se tornou fundamental para manter a conexão entre as pessoas, permitindo que as atividades cotidianas fossem realizadas remotamente. Durante a pandemia evidenciou-se a importância da tecnologia em diversos setores, desde a educação até a saúde, impulsionando tanto os avanços quanto a migração para o digital.

Na área da saúde, a pandemia impulsionou o desenvolvimento de aplicativos mobile para cuidados médicos e bem-estar. Com o distanciamento social, as pessoas passaram a utilizar mais dispositivos móveis para realizar consultas médicas, monitorar sua saúde e obter informações relevantes sobre a pandemia (PERRIN *et al.*, 2020).

Essa tecnologia tem um impacto significativo na vida dos pacientes, especialmente aqueles que lidam com doenças crônicas, que podem gerenciar sua saúde de maneira mais eficiente e evitar visitas presenciais frequentes. Além disso, como aponta Kay (2011) e Consulting (2009), a prática da medicina e da saúde pública tem sido beneficiada pela tecnologia móvel, que permite o gerenciamento e diagnóstico por parte dos profissionais de saúde por meio da *Mobile Health*, termo utilizado para descrever a prática da medicina e da saúde pública suportadas por dispositivos móveis e dispositivos de monitoramento de pacientes.

Além disso, a utilização de aplicativos mobile na área da saúde também tem impactado positivamente na qualidade do atendimento médico. Eles podem ajudar os profissionais de saúde a monitorar a saúde de seus pacientes de forma mais eficiente, gerenciar prescrições de medicamentos e agendamentos de consultas, além de melhorar a comunicação entre médicos e pacientes.

Correia *et al.* (2012) apresentaram um exemplo de como a aplicação de dispositivos móveis pode auxiliar o profissional de nutrição na realização de avaliações antropométricas, exames bioquímicos, avaliação dietética, cálculos energéticos, anamnese e dieta, facilitando o acesso às informações e melhorando a qualidade do atendimento prestado.

O uso de dispositivos móveis pode ser uma importante ferramenta no auxílio ao profissional de saúde na realização de exames e no gerenciamento da saúde de pacientes com Diabetes Mellitus (DM). O DM é um distúrbio metabólico crônico que afeta milhões de pessoas em todo o mundo. Segundo a Sociedade Brasileira de Diabetes (SBD, 2020), há cerca de 422 milhões de pessoas com DM, e essa doença é responsável por 1,6 milhão de

mortes por ano (BURIHAN; JÚNIOR, 2020). O DM ocorre quando os níveis de glicose no sangue estão elevados devido à produção insuficiente de insulina pelo corpo ou quando o corpo é incapaz de utilizá-la de forma eficaz, como destacado por Hong Sun (2022).

O DM é uma condição crônica que pode desencadear diversas complicações, entre as quais se destaca o pé diabético, com consequências que variam desde feridas crônicas até infecções e amputações dos membros inferiores. Segundo o Ministério da Saúde do Brasil (2013), o pé diabético é uma síndrome que acomete os membros inferiores de pessoas com DM, e a formação de úlceras é uma das suas manifestações mais comuns. Essas úlceras podem ter diversas causas, tais como neuropática, vascular e infecciosa (SALOMÉ *et al.*, 2011). Além disso, Alexiadou e Doupis (2012) constataram que entre 40 a 70% das amputações não traumáticas dos membros inferiores ocorrem em pacientes com DM e que as úlceras precedem aproximadamente 85% das amputações realizadas. Esses dados são alarmantes, pois a cada 30 segundos estima-se que um membro inferior é amputado em decorrência do DM, conforme Burihan e Júnior, no Consenso no tratamento e prevenção do pé diabético (BURIHAN; JÚNIOR, 2020).

De acordo com Ochoa-Vigo e Pace (2005), a maioria das amputações dos membros inferiores em pacientes com DM ocorre quando não há um tratamento e acompanhamento adequados pelas equipes de assistência primária. Nesse sentido, o desenvolvimento de um aplicativo para auxiliar os profissionais de saúde no diagnóstico e acompanhamento de pacientes com pé diabético pode ser uma solução eficaz para prevenir amputações e reduzir gastos hospitalares.

Esse aplicativo pode fornecer informações precisas sobre o histórico médico do paciente, avaliações periódicas e recomendações de tratamento com base em uma rede neural treinada para identificar padrões e processar as características capturadas na avaliação do paciente. Com essa tecnologia, os profissionais de saúde podem acompanhar o progresso do tratamento e tomar decisões mais assertivas, evitando complicações futuras e garantindo a melhoria da qualidade de vida dos pacientes. A implementação desse tipo de ferramenta pode ser um importante aliado para a saúde pública no combate ao pé diabético.

A inteligência artificial (IA) é uma área da ciência da computação que replica a forma como os seres humanos pensam, aprendem e retêm conhecimento. Ela é amplamente usada na análise de imagens e na previsão de resultados. Além disso, várias áreas da medicina estão trabalhando no desenvolvimento de técnicas de IA para melhorar a saúde em geral. (BRAGA, 2018).

No próximo capítulo, abordaremos uma doença específica, incluindo seus tipos, complicações e fatores de risco. Será fornecido informações precisas e atualizadas, tornando assim, um capítulo essencial para compreender a doença e suas implicações para a saúde.

2 DIABETES

O DM é uma doença crônica e grave que ocorre quando o organismo não produz insulina ou não a utiliza de forma eficaz. A insulina é um hormônio que regula o nível de glicose no sangue, e quando este se encontra em níveis elevados, ocorre a hiperglicemia, um efeito comum do DM não controlado. Com o tempo, se não tratada, a hiperglicemia pode causar sérios danos aos sistemas do corpo, levando a complicações de saúde incapacitantes e potencialmente fatais, como doenças cardiovasculares, lesão nervosa, doença renal e problemas oculares. No entanto, com o cuidado adequado do DM, essas complicações graves podem ser adiadas ou impedidas completamente (SUN, 2022).

Segundo um estudo realizado em 2021 pela Federação Internacional de Diabetes (International Diabetes Federation - IDF), o número de pessoas com diabetes mellitus tipo 1 (DM1) entre 0 e 19 anos de idade no mundo foi estimado em 1.211.900 milhões, com uma média de 149,5 mil novos casos surgindo anualmente. Já o diabetes tipo 2 (DM2) é a forma mais comum da doença e representa cerca de 90% dos casos de DM em todo o mundo, de acordo com a American Diabetes Association. Esse tipo de DM é em grande parte causado pelo excesso de peso corporal e inatividade física. Embora os sintomas possam ser semelhantes aos do DM1, muitas vezes são menos evidentes (SUN, 2022).

No Consenso no Tratamento e Prevenção do Pé Diabético, esclarece que o DM aparenta aumentar dramaticamente o risco de amputação da extremidade em função de infecções em úlceras que não cicatrizam no pé. As taxas de amputação na população com DM são cerca de 10 a 20 vezes as da população não diabética. Dentre estas amputações em pacientes diabéticos, 85% são precedidas por ulceração do pé que posteriormente acaba se deteriorando por gangrena ou infecção grave. No mundo, estima-se que a cada 30 segundos um membro inferior é amputado resultante de diabete (BURIHAN; JÚNIOR, 2020).

Ns Diretrizes da Sociedade Brasileira de Diabetes, Forti (2019) faz uma recomendação com relação à respeito da classificação do DM, a qual propõe uma classificação com base na etiopatogenia do diabetes, que compreende o DM1, o DM2, o diabetes gestacional (DMG) e outros tipos de diabetes, como mostra a Figura 1, página 13. Além disso, as diretrizes esclarece que há outras classificações sendo propostas, incluindo a classificação de subtipos de DM, levando em consideração característica clínicas, como

início, histórico familiar, função residual das células beta, índices de resistência à insulina, risco de complicações crônicas, grau de obesidade, presença de anticorpos e possíveis características sindrômicas. Na Figura 1, seguem algumas classificações da doença (FORTI *et al.*, 2019).

Figura 1 - Classificação do diabetes mellitus

<p style="text-align: center;">Diabetes tipo 1</p> <p>Imunomediado Idiopático</p>	<p style="text-align: center;">Outros tipos de Diabetes</p> <p>Doenças do pâncreas exócrino</p> <ul style="list-style-type: none"> • Pancreatite • Trauma ou pancreatectomia • Neoplasia pancreática • Fibrose cística • Hemocromatose • Pancreatopatia fibrocalculosa <p>Associado a endocrinopatias</p> <ul style="list-style-type: none"> • Acromegalia • Síndrome de Cushing • Glucagonoma • Feocromocitoma • Hipertireoidismo • Somatostatina • Aldosteronoma <p>Secundário a drogas (quimicamente induzido):</p> <ul style="list-style-type: none"> • Vacor (Piriminil - raticida com potencial para destruir célula Beta) • Pentamidina • Ácido nicotínico • Glicocorticoides • Hormônio de tireóide • Diazóxido • Agonista β adrenérgico • Tiazídicos • Difenilhidantoína • Interferon Y 	<p style="text-align: center;">Outros tipos de Diabetes</p> <p>Secundário a infecções</p> <ul style="list-style-type: none"> • Rubéola congênita • Citomegalovírus <p>Formas incomuns de DM imunomediado</p> <ul style="list-style-type: none"> • Síndrome da pessoa rígida • Síndrome de resistência à insulina tipo B (por anticorpos antirreceptor de insulina) <p>Outras síndromes genéticas associadas ao DM</p> <ul style="list-style-type: none"> • Síndrome de Down • Síndrome de Klinefelter • Síndrome de Turner • Síndrome de Wolfram • Síndrome de Prader Willi • Ataxia de Friedreich • Coreia de Huntington • Síndrome de Laurence-Moon-Biedl • Distrofia miotônica • Porfíria
<p style="text-align: center;">Diabetes tipo 2</p>		
<p style="text-align: center;">Diabetes gestacional</p>		
<p style="text-align: center;">Outros tipos de Diabetes</p> <p>Defeitos monogênicos na função das células β pancreáticas</p> <ul style="list-style-type: none"> • MODY (Mature Onset Diabetes of the Young) • Diabetes neonatal transitório ou permanente • Diabetes mitocondrial <p>Defeitos genéticos na ação da insulina</p> <ul style="list-style-type: none"> • Síndrome de resistência à insulina tipo A • Leprechaunismo • Síndrome de Rabson-Mendenhall • Diabetes lipotrófico 		

Fonte: Forti (2019).

Brasileiro *et al.* (2019) destaca que o diabetes compõe um importante problema de saúde pública devido à elevada prevalência e morbimortalidade, além do risco de desenvolvimento de complicações crônicas incapacitantes. Quanto às suas complicações crônicas, o pé diabético constitui a causa mais frequente de complicações, com uma alta taxa de amputação, internação prolongada e custo hospitalar elevado. Portanto, a etiologia multifatorial do pé diabético caracteriza-se por uma variedade de anormalidades resultante da combinação de neuropatia e/ou vasculopatia em pacientes portadores do DM (BRASILEIRO *et al.*, 2019).

2.1 Diabetes Tipo I

O DM1 é causado por um processo autoimune em que o sistema imunológico do corpo ataca as células beta produtoras de insulina do pâncreas (SUN, 2022).

Como resultado desse ataque, o corpo acaba produzindo pouca ou até mesmo nenhuma insulina. As causas desse processo não são totalmente compreendidas, porém, uma provável explicação é que a combinação dos fatores genéticos de susceptibilidade

(contado por inúmeros genes) e um gatilho ambiental, tal como infecção viral, pode iniciar uma reação autoimune.

O DM1 pode ser desenvolvido em qualquer idade, embora ocorra com mais frequência em crianças e jovens adultos. Durante a infância, o DM1 é uma das doenças crônicas mais comuns. O DM2 também é observado em crianças mais velhas e está aumentando em alguns países onde o sobrepeso e a obesidade infantil tornam-se mais comuns.

2.2 Diabetes Tipo II

O DM2 é o mais comum de diabetes, representando mais de 90% de todos os casos de DM em todo o mundo (SUN, 2022).

Diferente do DM1, no DM2 o fator hereditário e a obesidade têm maior importância. No DM2, a hiperglicemia é inicialmente o resultado da incapacidade das células do corpo de responder totalmente à insulina, condição essa denominada de resistência à insulina. O DM2 pode ter sintomas parecidos aos sintomas do DM1, porém, os sintomas são menos marcados e a condição pode ser completamente assintomática. Além disso, o momento exato do início do DM2 geralmente é impossível de se caracterizar.

2.3 Pé Diabético

Uma das complicações que o DM2 pode acarretar é o pé diabético. O pé diabético define-se como a entidade clínica de base etiopatogênica neuropática, induzida pela hiperglicemia sustentada, em que, com ou sem co-existência de doença arterial periférica (DAP), e com prévio traumatismo desencadeante, se produz ulceração do pé (SERRA, 2008).

Esse agravamento evitável é responsável pelo elevado número de amputações e internações hospitalares, gerando crescimento dos custos para os serviços de saúde, além de comprometer a produtividade e a qualidade de vida desses pacientes (TOSCANO *et al.*, 2018).

3 REDES NEURAIIS ARTIFICIAIS

A inteligência artificial pode ser definida como uma área da computação cujo objetivo é criar sistemas e algoritmos capazes de realizar tarefas que normalmente exigem inteligência humana, como aprender, raciocinar, perceber e tomar decisões (NORVIG; RUSSEL, 2013). O desenvolvimento da inteligência artificial tem sido motivado pela fascinação e inspiração do cérebro humano, considerado o órgão responsável pela inteligência humana. Compreender a estrutura e o comportamento do cérebro tem sido objeto de estudos há anos, levando à idealização de modelos computacionais baseados em redes neurais artificiais (RNA), que buscam imitar a maneira como o cérebro humano processa e aprende informações. Esses avanços na IA permitem a criação de sistemas e algoritmos que podem realizar tarefas complexas de forma autônoma e aprender com experiências anteriores, como uma forma de simular as habilidades cognitivas humanas (TORTORA, 2018).

A composição do cérebro biológico se dá por uma quantidade considerável de células nervosas chamadas de neurônios. Haykin (2001) dispõe o cérebro como um computador altamente complexo devido a sua enorme capacidade de processar e, principalmente, generalizar informações de maneira não-linear e paralela. Os estudos sobre o comportamento do cérebro pelos estudiosos de inteligência computacional tem especial interesse em como se dá o aprendizado. Tortora (2018) define esse aprendizado como a capacidade de adquirir novas informações ou habilidades por meio de instruções, ou experiência, o aprendizado está diretamente ligado ao conceito de neuroplasticidade, ou seja, o cérebro consegue reconfigurar sua estrutura neuronal conforme as novas informações que recebe.


Inspirada na maneira como o cérebro processa informações e aprende, as redes neurais artificiais são uma abstração computacional que apresenta a modelagem matemática da estrutura de neurônios do cérebro. Na sua forma mais geral, uma rede neural é uma máquina em que é projetada para modelar a maneira como o cérebro realiza uma tarefa particular ou função de interesse (HAYKIN, 2001). Uma das características mais importantes de uma rede neural artificial é a sua capacidade de aprender a partir do ambiente, por meio de exemplos, conseguindo, portanto, melhorar seu desempenho. Isso é feito por um processo iterativo de ajustes empregados aos seus parâmetros livres (pesos sinápticos e níveis de *threshold*) (SILVA, 2010). Um dos pontos fortes das redes neurais é a capacidade de resolução de problemas complexos não-lineares.

3.1 Neurônio Artificial

Para compreender o funcionamento das RNAs, é crucial entender o neurônio biológico, que serviu como inspiração para a criação do neurônio artificial. O neurônio biológico é a unidade básica do cérebro e possui uma característica singular de se conectar com outros neurônios, formando, assim, redes complexas capazes de processar informações e armazenar o aprendizado obtido ao longo do processo. Portanto, antes de se aprofundar no neurônio artificial, é fundamental compreender a importância e o funcionamento do neurônio biológico na formação das RNAs.

Como qualquer célula biológica, o neurônio é delimitado por uma membrana celular delicada que não só protege suas funções biológicas, mas também desempenha um papel crucial para o funcionamento elétrico da célula nervosa. Além disso, sua principal função é receber, processar e transmitir impulsos nervosos, permitindo que o cérebro processe e armazene informações. O neurônio também consegue reagir a estímulos externos, o que é essencial para o funcionamento adequado do sistema nervoso. A estrutura e o funcionamento do neurônio são fundamentais para entender como as redes neurais artificiais são criadas e funcionam. Sua estrutura pode ser ilustrada pela Figura 2.

Figura 2 - Neurônio Biológico.



Fonte: Growiz (2022)

Tratando-se ainda da estrutura, de acordo com Kovács (2002), o neurônio pode ser dividido em três partes principais:

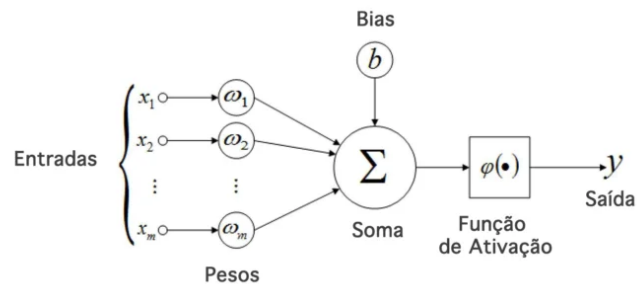
- Soma, ou núcleo celular, responsável pelo processamento metabólico;
- Os dendritos, ramificações que recebem estímulos de outras células nervosas;
- E o axônio, que conecta o neurônio a outras células nervosas e transmite os estímulos.

Essas partes trabalham em conjunto para o neurônio poder receber, processar e transmitir informações, sendo assim, cada uma delas é fundamental para o funcionamento do sistema nervoso. A figura 2 ilustra a estrutura do neurônio, evidenciando a localização dessas partes.

Os impulsos recebidos (que constituem a informação) pelos dendritos são metabolizados no núcleo celular e podem ser transmitidos pelo axônio para outros neurônios, seguindo a direção mostrada na ilustração, esse evento é conhecido como sinapse. Kovács (2002) diz que o neurônio possui um potencial de ação, sendo uma rápida mudança do potencial elétrico das membranas dos neurônios, em seu estado neutro, o interior do axônio está com carga inferior ao seu exterior, quando acontece a mudança o seu interior torna-se mais carregado que seu exterior, fazendo com que o neurônio assuma o estado de excitado.

O neurônio artificial é uma representação simplificada do neurônio biológico, criado por meio de modelagem matemática. Ele é amplamente utilizado em estudos de redes neurais e inteligência artificial, e sua estrutura pode ser visualizada na Figura 3.

Figura 3 - Neurônio Artificial



Fonte: Growiz (2022)

O neurônio representado na Figura 3 foi originalmente desenvolvido por McCulloch e Pitts (1943) para realizar o processamento de uma ou mais entradas. A estrutura deste neurônio é inspirada no neurônio biológico, onde as entradas são associadas aos dendritos, o processamento é realizado pelo soma e a saída é comparável ao axônio. Cada entrada é ponderada por um peso que representa a força da conexão sináptica. Esses pesos são somados no corpo celular, representado na Figura 3 como um somador, e então processados pela função de ativação, que substitui o potencial de ação do neurônio biológico.

Uma representação matemática comum do neurônio artificial inclui a entrada de sinais representados por x_j , onde j denota a sinapse conectada ao neurônio k , multiplicada pelo peso sináptico correspondente w_{kj} . O neurônio k então realiza uma soma ponderada dos sinais de entrada, passada para uma função de ativação para gerar a saída. Em alguns casos, a saída é limitada por um valor máximo, o que pode resultar em diferentes respostas do neurônio artificial.

3.1.1 Função de Ativação

A função de ativação é uma importante peça no neurônio artificial, que após receber o valor da soma ponderada, tem a responsabilidade de restringir o valor de saída em um intervalo especificado. Essa função pode assumir diversas formas, podendo ser uma função parcialmente diferenciada ou totalmente diferenciada. De acordo com Haykin (2001), existem diversos tipos de funções de ativação, sendo as mais populares:

- **Função Limiar:** A função limiar é uma função de ativação que restringe a saída da rede neural em valores binários, sendo 0 ou 1. Ela é usada para a classificação de dados em problemas de aprendizado de máquina. Segundo Haykin (2001), a função limiar serve para lidar com problemas de classificação binária simples, mas pode não ser adequada para problemas mais complexos.
- **Função Linear por Partes:** A função linear por partes é uma função de ativação que permite a operação linear de entrada até um certo ponto, onde ocorre a saturação e a saída se mantém constante. Isso permite que a rede neural seja mais sensível a variações em regiões específicas do espaço de entrada. Haykin (2001) afirma que essa função é útil para problemas que requerem a operação linear até um certo ponto e, em seguida, uma resposta constante para valores acima desse ponto.
- **Função Sigmoidal:** A função sigmoidal é uma função de ativação que suaviza as mudanças na saída da rede neural, permitindo que a rede possa ser treinada com algoritmos mais eficientes. Ela é amplamente utilizada em problemas de classificação e regressão. Segundo Haykin (2001), a função sigmoidal é particularmente útil para problemas que envolvem a saída de valores contínuos.
- **Função Tangente Hiperbólica:** A função de ativação tangente hiperbólica é semelhante à função sigmoidal, mas sua curva é mais acentuada, o que significa que ela produz valores de saída mais próximos de -1 ou +1 quando os valores de entrada são grandes. A vantagem da tangente hiperbólica sobre a sigmoidal é que ela tem uma simetria em torno do ponto (0, 0). Essa função de ativação é frequentemente usada em redes neurais recorrentes e em problemas de regressão. Haykin (2001) menciona que a tangente hiperbólica é uma função parcialmente diferenciável e sua derivada pode ser facilmente calculada a partir da sua função.
- **Função ReLU:** A função de ativação ReLU é um componente fundamental em redes neurais profundas, e sua popularidade se deve a uma combinação de várias vantagens que ela apresenta, e uma dessas vantagens é a sua simplicidade. Essa função é fácil de

compreender e implementar, exigindo apenas uma verificação se o valor de entrada é positivo ou negativo. Além disso, sua eficiência computacional é muito alta, o que significa que ela pode ser usada em redes neurais profundas com milhões ou bilhões de parâmetros. Outra vantagem da função ReLU é que ela é capaz de modelar relações não lineares entre as entradas e as saídas da rede neural. Isso é importante porque muitos problemas do mundo real são intrinsecamente não lineares e requerem uma abordagem não linear para serem resolvidos. A função ReLU permite que a rede neural aprenda essas relações não lineares de forma eficaz. Além disso, a função ReLU ajuda a mitigar o problema da dissipação do gradiente, que ocorre quando o gradiente se torna tão pequeno que a rede neural não consegue aprender novos pesos. Isso acontece em redes neurais profundas com muitas camadas, onde o gradiente pode se dissipar ao se propagar para trás pela rede. A função ReLU tem derivada constante igual a 1 para valores positivos e 0 para valores negativos, o que facilita a propagação do gradiente pela rede. Em suma, a função de ativação ReLU é uma escolha popular em redes neurais profundas devido à sua simplicidade, eficiência computacional, não-linearidade e capacidade de mitigar o problema da dissipação do gradiente. Se você está construindo uma rede neural profunda, é muito provável que a função ReLU esteja entre as opções de funções de ativação que você considerará (SCHMIDT-HIEBER, 2020).

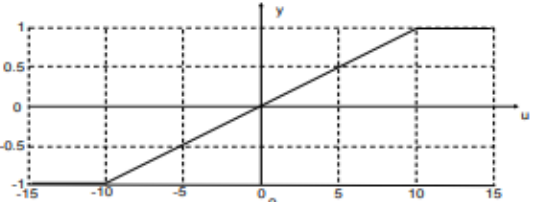
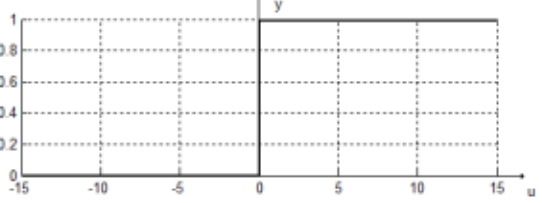
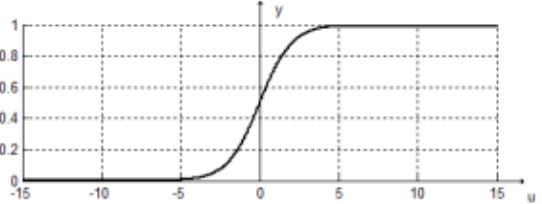
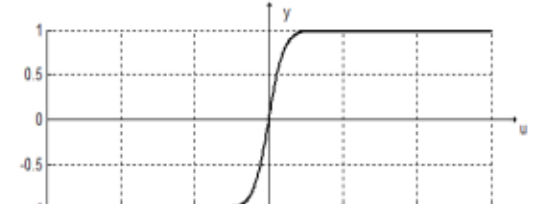
- **Função Softmax:** A função de ativação Softmax é frequentemente usada em redes neurais para classificação multiclasse. Ela é uma função matemática que converte um vetor de números em um vetor de probabilidades, em que cada elemento do vetor de saída representa a probabilidade de pertencer a uma determinada classe. A função Softmax é definida como uma exponenciação normalizada de um vetor de entrada, em que cada elemento do vetor de saída é calculado dividindo-se a exponenciação do elemento correspondente do vetor de entrada pela soma das exponenciações de todos os elementos do vetor de entrada. Isso garante que o vetor de saída seja um vetor de probabilidades, cuja soma de todos os elementos é igual a 1. A função Softmax é amplamente usada em problemas de classificação multiclasse, pois é capaz de mapear as saídas de uma rede neural em probabilidades que podem ser usadas para classificar um determinado objeto em uma ou várias classes. A função Softmax é diferenciável e é frequentemente usada como a última camada de uma rede neural em problemas de classificação multiclasse. No entanto, é importante lembrar que a função Softmax é sensível a *outliers* e pode ser afetada por problemas de desequilíbrio de classe, em que

uma ou mais classes têm muito poucos exemplos de treinamento. Em tais casos, outras abordagens, como a função *Focal Loss*, podem ser mais adequadas (RIZZO; CANATO, 2020).

Com base nas conceituações apresentadas, é possível visualizar no Quadro 1, produzido por Silva (2014), exemplos de funções de ativação com seus respectivos gráficos.

Essas funções são essenciais no processamento de informações em redes neurais artificiais, pois limitam a saída do neurônio em um intervalo específico após receberem a soma ponderada das sinapses. As diferentes formas que essas funções podem assumir, seja parcial ou totalmente diferenciáveis, oferecem uma variedade de escolhas ao projetar uma rede neural.

Quadro 1 - Funções de ativação e seus respectivos gráficos.

Função de Ativação	Gráfico da Função de Ativação
Rampa simétrica $\varphi(v) = \begin{cases} a, & \text{se } v_k > a \\ v, & \text{se } a \leq v_k \leq a \\ -a, & \text{se } v < a \end{cases}$	 <p>(a) Gráfico de ativação rampa simétrica.</p>
Limiar $\varphi(v) = \begin{cases} 1, & \text{se } v_k \geq 0 \\ 0, & \text{se } v_k < 0 \end{cases}$	 <p>(b) Gráfico de ativação degrau bipolar.</p>
Sigmóide $\varphi(v) = \frac{1}{1 + \exp(-av)}$	 <p>(c) Gráfico de ativação logística.</p>
Tangente hiperbólica $\varphi(v) = \frac{1 - \exp(-av)}{1 + \exp(-av)}$	 <p>(d) Gráfico de ativação tangente hiperbólica.</p>

Fonte: SILVA, 2014.


3.2 Arquitetura das Redes Neurais

Um único neurônio possui um poder limitado de processamento; por isso, são geralmente agrupados e interconectados em uma rede para que unidos possam assumir um valor maior de processamento, nessa seção serão discutidas algumas arquiteturas de redes neurais artificiais, cada uma possui foco em resolver determinada categoria de problema, simples ou complexo.

Uma das maiores dificuldades encontradas no uso das redes neurais é a escolha da melhor arquitetura, uma vez que esse processo é experimental e demanda um grande tempo de execução. Na prática, o processo deve ser aplicado com o intuito de testar vários métodos de aprendizado e as diferentes configurações que uma rede possa ter para a resolução de um problema em específico (MIRANDA *et al.*, 2009). De modo geral, pode-se identificar três classes de arquitetura de rede diferentes: rede Neural Feedforward de uma camada, Rede Neural Feedforward Multicamadas e Redes Recorrentes ou Realimentadas.

- Rede *Feedforward* de uma camada: Aqui os neurônios são organizados em forma de camadas, assim como pode ser visto na Figura 4, os nós da camada de entrada se ligam diretamente com a camada de saída. As arquiteturas do tipo *feedforward* apresentam uma organização similar à do córtex humano, nas quais os neurônios se dispõem em camadas paralelas e consecutivas, e os axônios se estendem sempre no mesmo sentido, ou seja, a informação se propaga da entrada para a saída, sem existir ligações entre uma mesma camada ou com camadas anteriores. Essa arquitetura é chamada de rede de uma camada, fazendo alusão à camada de saída, onde os nós de entrada não processam, somente apresentam os padrões à rede.

Figura 4 - Rede *feedforward* de uma camada




Fonte: Rede Neural Artificial - Blocos de Construção (2022)

- *Feedforward* Multicamadas: diferente da classe anterior, esta pode apresentar uma ou mais camadas escondidas, onde a função dos neurônios escondidos é interferir entre a

camada de entrada e a de saída da rede. Com o incremento de mais camadas, a rede passa a mapear melhor problemas mais complexos.

Como essa rede é do tipo *feedforward*, as conexões sempre estarão no sentido da camada de entrada para a camada de saída. Quando a rede possuir todos os nós de uma camada se comunicando com os da camada posterior, então ela é dita como totalmente conectada, e caso alguma dessas conexões sinápticas não estejam ligadas, a rede é dita como parcialmente conectada. A Figura 5, retrata uma rede *feedforward* multicamada totalmente conectada.


Figura 5 - Rede *feedforward* multicamadas



Fonte: Rede Neural Artificial - Blocos de Construção (2022)

- Rede recorrente/realimentada: diferente das redes do tipo *feedforward*, as redes recorrentes permitem a realimentação de uma camada com as informações geradas pela camada subsequente, ou ainda realizar uma realimentação do neurônio com sua própria saída, chamado de *self-feedback*. Para que essa realimentação aconteça, um dispositivo de atraso é incluído, guardando as informações de saída de um momento anterior até que ela possa ser fornecida como entrada do momento atual. A Figura 6, página 23, apresenta uma rede *self-feedback*.

Figura 6 - Rede realimentada



Fonte: Rede Neural Artificial - Blocos de Construção (2022)

As redes do tipo feedforward podem, de forma particular, serem consideradas um caso de rede realimentada. Estas últimas são mais poderosas, porém são bem mais complexas, tanto para utilização quanto para a análise dos resultados apresentados.

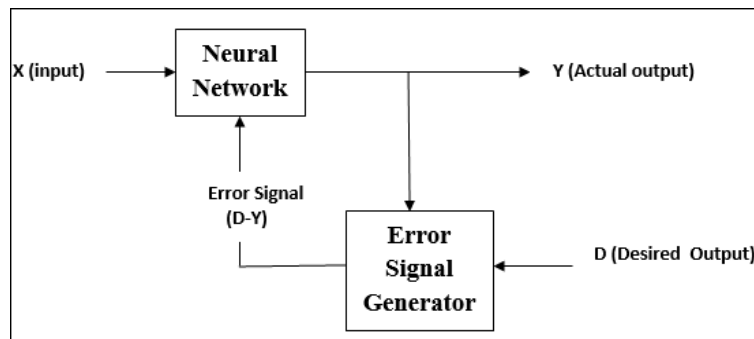
3.3 Processo de Aprendizagem

Independente de como foi implementada a rede neural artificial, de qual arquitetura e qual função de ativação, o que importa é a maneira como a rede neural aprende. Haykin (2001) diz que o processo de aprendizagem de uma rede neural se dá pelas alterações em seus pesos sinápticos, modificados em decorrência de estímulos do ambiente no contexto em que está a rede.

É importante destacar que a arquitetura da rede neural desempenha um papel crucial no processo de aprendizagem. Nesse sentido, é possível identificar duas categorias que englobam a maioria das arquiteturas de redes neurais, as quais apresentam diferenças fundamentais em sua organização e funcionamento. Sendo elas:

- **Aprendizagem supervisionada:** como o próprio nome sugere, envolve a presença de um "supervisor" externo que fornece à rede neural informações corretas sobre a saída esperada para cada entrada. Isso é descrito por Haykin (2001) como aprendizagem por correção de erro, que se dá de maneira iterativa, pois a cada iteração o valor de saída é comparado ao valor de saída desejado para o neurônio em questão, os ajustes serão aplicados em sequência nos pesos sinápticos de acordo com essa diferença (Figura 7, página 24). Nesse tipo de aprendizagem, a rede conhece os valores de saída ideais e vai se adaptando até que os pesos não necessitem mais de ajustes.


Figura 7 - Aprendizagem supervisionada



Fonte: Rede Neural Artificial - Blocos de Construção (2022)

- Aprendizagem não-supervisionada: esta rede neural recebe dados não rotulados e deve tentar encontrar padrões ou estruturas significativas neles, sem a ajuda de informações externas (Figura 8). Isso pode ser feito usando técnicas como *clustering*, que agrupa os dados em clusters com base em sua semelhança, ou redução de dimensionalidade, que procura reduzir a quantidade de informações a serem processadas pela rede, mantendo as informações mais importantes. Haykin (2001) destaca que a aprendizagem não-supervisionada é mais desafiadora, uma vez que a rede precisa descobrir sozinha as características importantes dos dados, mas pode ser extremamente útil em situações em que não há informações rotuladas disponíveis.

Figura 8 - Aprendizagem não-supervisionada



Fonte: Rede Neural Artificial - Blocos de Construção (2022)

A tecnologia tem sido uma grande aliada para os profissionais da área de saúde, proporcionando inúmeras possibilidades para melhorar a qualidade do atendimento, diagnóstico e tratamento de pacientes. No capítulo a seguir, serão apresentadas algumas das principais tecnologias que foram utilizadas para que este estudo possa auxiliar os profissionais no aprimoramento do cuidado com a saúde.

4 TECNOLOGIAS EM SAÚDE

Neste capítulo, serão apresentados alguns estudos relevantes que aplicam técnicas de inteligência computacional na área da saúde, com destaque para o tratamento e monitoramento de pacientes com diabetes. Serão abordados artigos científicos, trabalhos de conclusão de curso, dissertações e teses que exploram o potencial da inteligência computacional para melhorar a precisão do diagnóstico, a predição de complicações e o controle glicêmico, contribuindo assim para uma abordagem mais eficiente e personalizada no tratamento dessa doença crônica.

As redes neurais têm sido amplamente utilizadas para previsão e diagnóstico de DM. O DM é uma doença crônica que afeta milhões de pessoas em todo o mundo e a previsão precoce pode ajudar no tratamento e gestão da doença.

Um estudo realizado por Ahangar *et al.* (2022) utilizou uma rede neural para prever o risco de DM2 em pacientes com pré-diabetes. Os resultados mostraram que a rede neural teve uma precisão de 86,75% na previsão do risco de DM2 (MOGHADDAM, PARVANEH, GHOBADIAN, AND AHANGAR, 2022).

Além disso, redes neurais também foram usadas para diagnosticar diabetes com alta precisão. Um estudo realizado por Singh *et al.* (2005) utilizou uma rede neural para diagnosticar diabetes com base em características clínicas e de laboratório. A precisão da rede neural foi de 91,53%, o que é uma taxa alta e promissora para um sistema de diagnóstico (SINGH, NALINI, ARMSTRONG, AND LIPSKY, 2005).

Outro estudo recente realizado por Mansoor *et al.* (2020) utilizou uma rede neural convolucional para classificar retinopatia diabética em imagens de fundo de olho. A rede neural atingiu uma precisão de 96,75% na classificação de diferentes estágios de retinopatia diabética, o que é uma taxa muito alta e sugere que a rede neural pode ser uma ferramenta útil para o diagnóstico precoce de complicações oculares em pacientes diabéticos (MANSOOR; HASSAN, *et al.*, 2020).

No trabalho de Marinho *et al.* (2019), intitulado "Assistente inteligente para auxiliar na prevenção do diabetes tipo 2", objetivou criar um aplicativo que auxilie no controle e prevenção da doença. O conhecimento especializado e estruturado é disponibilizado no assistente inteligente, que monitora e analisa a situação do usuário com base em dados como peso, circunferência abdominal, índice de massa corporal (IMC), glicemia em jejum, alimentação e prática de exercícios. O aplicativo aconselha os usuários com base na análise realizada e os orienta sobre procedimentos preventivos e cuidados a serem tomados em

relação à sua saúde. As variáveis e regras de inferência utilizadas para a construção da base de conhecimento foram elencadas e definidas por meio de reuniões com especialistas e estudos da literatura, incluindo a Federação Internacional do Diabetes (IDF) e a Sociedade Brasileira de Diabetes (SBD) (MARINHO *et al.*, 2019).

No contexto da prevenção do DM2, a aprendizagem de máquina é aplicada por meio da modelagem de uma árvore de decisão no software. As informações do paciente são um estado da árvore, sendo analisado e processado iterativamente, gerando um diagnóstico com base nas informações disponibilizadas. O principal objetivo do trabalho é disponibilizar um aplicativo para dispositivos móveis que auxilie na prevenção do DM2, com foco em pessoas com pré-diabetes e não diabéticos. A premissa é de que, sugerindo, apoiando e acompanhando mudanças no estilo de vida, é possível diminuir o índice de evolução de pré-diabetes para diabetes, o que pode ser importante para populações de baixa renda e geograficamente remotas com dificuldades de acesso a um especialista para acompanhamento contínuo.

O estudo conduzido por Farias (2021), intitulado "Controle Inteligente para um Pâncreas Artificial utilizando Redes Neurais Artificiais", propõe um modelo para desenvolver um controlador não linear inteligente para um pâncreas artificial, que utilize um compensador por redes neurais artificiais do tipo função de base radial (RBF). Este modelo tem como finalidade regular automaticamente a concentração de glicose no sangue de pacientes que sofrem de diabetes mellitus tipo 1. Para simular a dinâmica do paciente virtual, foi utilizado o modelo IVP (Identifiable Virtual Patient) glicêmica, que gera pacientes virtuais e refeições aleatoriamente, variando os parâmetros dos pacientes de forma senoidal ao longo da simulação. Os resultados obtidos a partir das simulações demonstraram que o controle inteligente proposto foi eficaz na regulação glicêmica, lidando com mudanças no sistema de forma contínua e adaptativa. Essa abordagem pode ser considerada promissora para o desenvolvimento de dispositivos de pâncreas artificial, capazes de proporcionar uma vida mais confortável e autônoma aos pacientes com DM1 (FARIAS, 2021).

Em sua dissertação, Silva (2014) expõe o uso de redes neurais na construção de um modelo preditivo para identificação de pacientes com potencial para desenvolver pré diabético de maneira não invasiva, utilizando algoritmo K-Means, o autor propõe para trabalhos futuros a utilização de uma com boa usabilidade para coleta de dados para a predição, com objetivo de que seja utilizado em unidades básicas de saúde para triagem de pacientes (SILVA, 2014).

Outro autor que utiliza a rede neural em sua tese para apoiar o diagnóstico de DM2, com foco em predições, é Araújo (2021), em que explorando métodos invasivos e não invasivos obtém um modelo com acurácia de 82.28%. Esse modelo é uma ferramenta eficiente para auxiliar os profissionais da saúde a minimizar erros médicos e proporcionar diagnósticos mais detalhados e rápidos. O estudo ressalta a importância do pré-processamento dos dados e do design da rede neural na obtenção de resultados precisos. A pesquisa também destaca a relevância de ferramentas computacionais para o diagnóstico de doenças graves, como diabetes, câncer e doenças cardiovasculares, apresentados em outros estudos na literatura, que requerem modelos para auxiliar os profissionais da saúde em seu diagnóstico (ARAÚJO, 2021).

Este trabalho pretende de forma objetiva, contribuir para a melhoria do processo de acompanhamento de pacientes com feridas de pé diabético, utilizando redes neurais para recomendar condutas personalizadas ao profissional da saúde responsável pelo tratamento.

Com base em estudos correlatos que utilizam redes neurais para solucionar problemas relacionados à diabetes e suas complicações, esta pesquisa apresenta uma abordagem inovadora para a resolução desse problema específico. Por meio da análise de dados do paciente sobre a ferida, a rede neural consegue identificar padrões e recomendar condutas individualizadas.

Dessa forma, espera-se que os resultados obtidos com este trabalho possam aprimorar o tratamento de pacientes com feridas de pé diabético, melhorando sua qualidade de vida e bem-estar.

Até o momento, não foram apresentados os detalhes sobre as ferramentas utilizadas na criação da aplicação e como elas foram empregadas. No próximo capítulo, abordaremos todas essas informações, desde a seleção das tecnologias até o processo de desenvolvimento, a fim de fornecer uma visão completa do projeto.


5 METODOLOGIA

Um projeto de desenvolvimento de software consiste em resolver problemas utilizando-se, para isto, de metodologias tradicionais e ágeis de desenvolvimento de *software*, aplicações, frameworks, sistemas, tecnologias e banco de dados, a fim de obter um produto final como: websites, aplicativos *desktop* e *mobile*, *bots*, códigos de automação, entre outros que resolvam parte ou a totalidade de um problema. Com isso, entende-se que existem diversas etapas a serem cumpridas durante o ciclo de vida de um projeto de *software*. Essas etapas podem compor uma série de paradigmas que corresponde aos passos metodológicos, são eles: modelos tradicionais (cascata, incrementais, prototipagem, evolucionários e processo unificado) e modelos ágeis (*Extreme Programming* (XP), *Scrum*, etc) (PRESSMAN, 2011).

Para realizar a aplicação proposta neste trabalho, utilizou-se o Processo Unificado (PU) que consiste em um processo de desenvolvimento de *software* que pode envolver mais de um modelo de processo de *software*, em vez de um único processo (TSUI; KARAM, 2013). A escolha do PU se deu, por ser um processo mais moderno, com fases e atividades bem definidas como mostra na Figura 9, página 29, as quais apoiam-se nas características de ciclos iterativos e incrementais, caracterizando-se, portanto, como uma abordagem completa para o processo de desenvolvimento de *software* (TSUI; KARAM, 2013; SOMMERVILLE, 2011; PRESSMAN, 2011).

Esse processo pode ser empregado em projetos de pequeno, médio e grande porte, com ambos empregando as fases de concepção, elaboração, construção e transição. Já as atividades presentes no PU são: modelagem do negócio, requisitos, análise e projeto, implementação, teste e implantação (KRUCHTEN, 2003; SOMMERVILLE, 2011).

Figura 9 - Processo Unificado



Fonte: RUP - Rational Unified Process (2023).

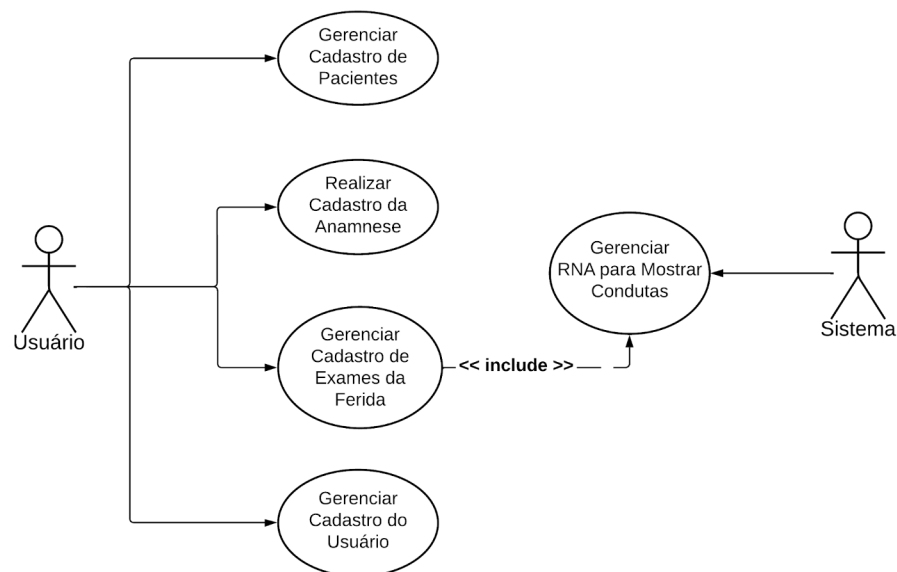
5.1 Etapas do Estudo

Para a realização das etapas do estudo, o processo unificado serviu de base para nortear o desenvolvimento do aplicativo. A seguir serão descritas as atividades e ferramentas envolvidas em cada fase do processo de desenvolvimento do aplicativo DIAFOOT.

5.1.1 Fase de Concepção

Nesta fase, buscou-se estabelecer um bom entendimento do escopo do projeto, obtendo, primeiramente, um entendimento de alto nível dos requisitos a serem tratados para o projeto. No que se refere às atividades do processo unificado, o foco foi o levantamento e entendimento dos requisitos referentes aos tipos de coberturas para as úlceras venosas e aos tipos requisitos para a classificação das lesões para um pé diabético, ambos requisitos se referindo as informações de saída e de entrada para o aplicativo DIAFOOT, respectivamente. Os requisitos referentes às informações do paciente também foram levantados. Para melhor compreensão de como os requisitos são manipulados pelo sistema elaborou-se o diagrama de casos de uso visualizado na Figura 10, página 30.

Figura 10 - Diagrama de caso de uso da aplicação



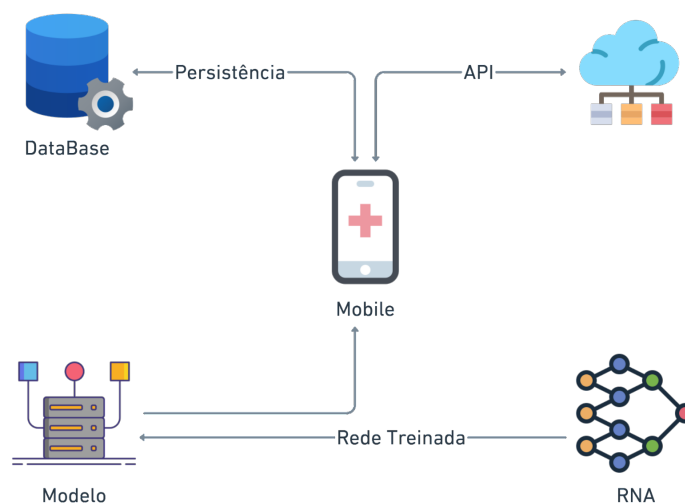
Fonte: Compilação do autor.

5.1.2 Fase de Elaboração

Os objetivos desta fase foram analisar o domínio do problema e estabelecer a arquitetura do sistema. Assim, em termos do processo de desenvolvimento, o foco foram as atividades de análise e projeto.

A realização das atividades de análise e projeto envolveram, em primeiro lugar, o planejamento da arquitetura geral do sistema Figura 11, com base nos requisitos levantados, no contexto, a RNA foi construída e treinada fora da aplicação *Mobile*, depois foi gerado o modelo para ser integrado, a aplicação que interage com o banco de dados *Realtime Database* e também com a *application programming interface* (API), ambos serviços do *firebase* para utilização de serviços como autenticação e armazenamento de imagens na nuvem. Em segundo lugar, foram definidas as arquiteturas detalhadas tanto para o aplicativo DIAFOOT quanto para a rede neural utilizada pelo aplicativo.

Figura 11 - Arquitetura detalhada da aplicação



Fonte: Compilação do autor.

A arquitetura detalhada do aplicativo foi dividida em duas partes: um *front-end* e *back-end*. Para a modelagem das interfaces gráficas do *front-end* utilizou-se a ferramenta de design Figma[®], que é uma ferramenta destinada para prototipagem de interfaces gráficas de usuário e desenvolvimento de UI/UX. Na Figura 12 visualizam-se os protótipos das telas dos módulos Captura das Características, Classificador e Interpretador, ambas modeladas com o Figma[®].

Figura 12 - Prototipagem da aplicação: Captura das Características.

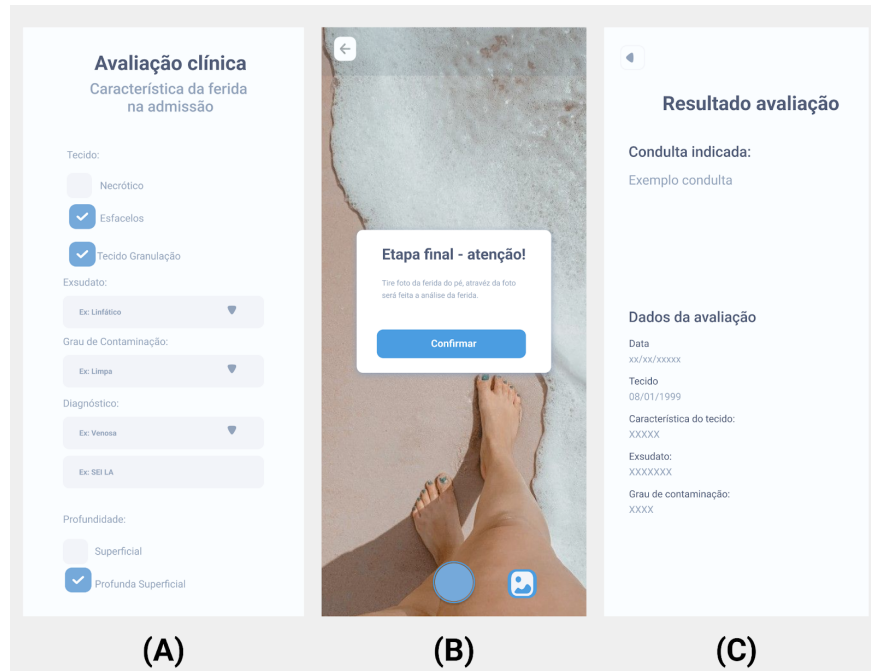
The figure displays four sequential screens of a mobile application for clinical evaluation, labeled 1/4 through 4/4. Each screen has a status bar at the top showing the time as 9:12 and various system icons.

- Screen 1/4: Avaliação clínica - Antecedentes pessoais**. It features a list of checkboxes for personal history: Diabetes Mellitus, Hipertensão Arterial Sistêmica, Tabagismo, Etilismo, Neoplasia:, Cardiopatia:, Alergias:, Cirurgias anteriores:, and Outras doenças:. At the bottom are 'Cancelar' and 'CONFIRMAR' buttons.
- Screen 2/4: Avaliação clínica - Antecedentes familiares**. It features a list of checkboxes for family history: Diabete miltus, Hipertensão Arterial Sistêmica, Neoplasia:, Cardiopatia:, Pneumopatias:, and Outras doenças:. At the bottom are 'Voltar' and 'CONFIRMAR' buttons.
- Screen 3/4: Avaliação clínica - História da ferida**. It includes a date field for 'Primeira incidência:' (22/03/2023), a dropdown menu for 'Etiologia:' (Ecolher), and a checkbox for 'Recidivada:'. At the bottom are 'Voltar' and 'CONFIRMAR' buttons.
- Screen 4/4: Avaliação clínica - Exame físico**. It includes a checkbox for 'Programa de Benefício de Medicamento' and input fields for 'Pressão arterial (mmHg)' (Ex: 18/5), 'Peso (kg)' (Ex: 67,90), 'Temperatura (°C)' (Ex: 36), 'Incrusões respiratórias por minuto (mm)' (Ex: 25), and 'Índice de massa corporea' (Ex: 25). At the bottom are 'Voltar' and 'CONFIRMAR' buttons.

Fonte: Compilação do autor.

O módulo Captura Características (Figura 12) serve para receber do profissional de saúde as informações referentes às características constatadas no pé diabético do paciente, tais como: cor; quantidade de exsudato; odor, as quais servirão como dados de entrada para o classificador.

Figura 13 - Prototipagem da aplicação: Classificador e Interpretador.



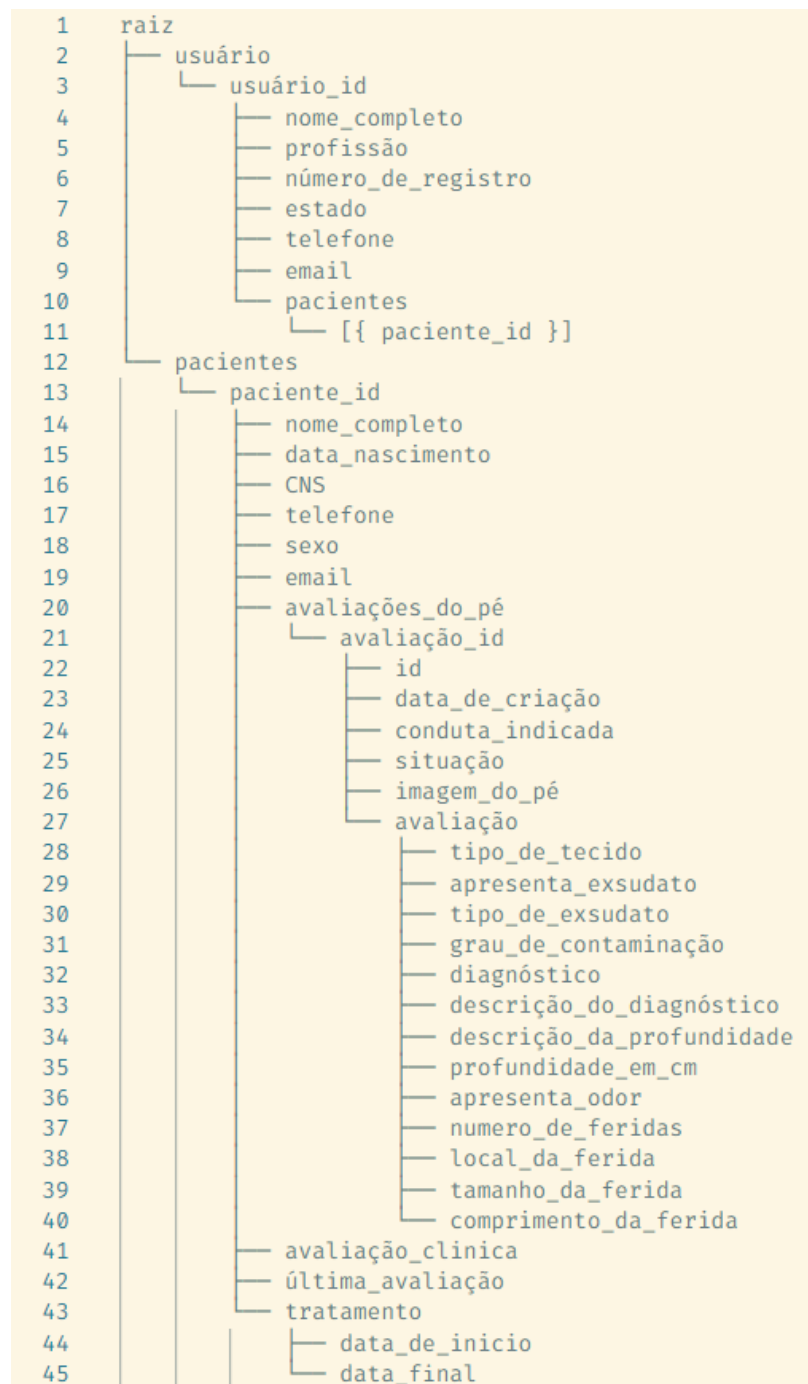
Fonte: Compilação do autor.

O módulo Classificador (Figura 13(A)) serve para realizar a classificação da lesão presente no pé diabético e a escolha da cobertura.

Já o módulo Avaliador e Interpretador (Figura 13(B)) revela as sugestões de coberturas para o tratamento da lesão presente no pé diabético.

Para o *back-end*, a modelagem esteve direcionada para um banco de dados *NoSQL* (Figura 14, página 33), que ao contrário dos bancos de dados relacionais, que seguem um modelo de dados rigidamente estruturado, permite um alto grau de flexibilidade na modelagem dos dados, além de serem escaláveis e distribuídos, no caso do aplicativo foi usado o banco de dados *Realtime Database* que é um serviço de banco de dados fornecido pelo *Firebase* que possui um plano de dados gratuito e uma interface relativamente simples de ser integradas a aplicações mobile.

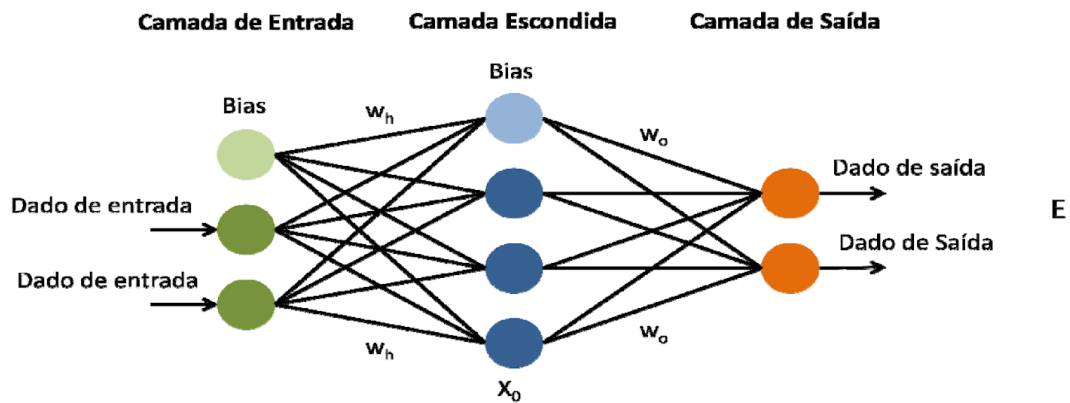
Figura 14 - Modelagem NoSQL do banco de dados utilizado.



Fonte: Compilação do autor.

Para a modelagem da RNA, verificou-se a necessidade de um estudo prévia para escolher o tipo de arquitetura, quantidade de camadas, quantidade de neurônios artificiais por camada, algoritmo de aprendizagem e função de ativação. Após o estudo e devido a complexidade do problema a ser solucionado, optou-se pelo uso de uma Rede Neural FeedForward (FF) (Figura 15, página 34).

Figura 15 - Rede Neural FeedForward - FF



Fonte: Tissot, Camargo e Pozo (2012).

Em uma rede feedforward, cada camada se conecta à próxima camada, porém não há um caminho de volta, portanto, todas as conexões têm a mesma direção, partindo da camada de entrada rumo à camada de saída.

Existem algumas formas de estruturar uma rede feedforward. Mas a princípio, devemos definir a camada de entrada, camada(s) intermediária(s) e a camada de saída. Apesar de existirem técnicas básicas, alguns experimentos são necessários para que seja definida uma estrutura ótima da rede.

- **Camada de Entrada:** A camada de entrada é a primeira etapa do processo em uma rede neural, onde um padrão é apresentado para a rede e cada neurônio é responsável por representar uma variável independente que afeta o resultado final. Essa camada é crucial para o sucesso da rede neural, pois a qualidade e a quantidade das variáveis independentes afetam diretamente a precisão e a eficácia da previsão da rede. Portanto, é importante que essas variáveis sejam selecionadas cuidadosamente para garantir que a rede possa aprender e generalizar padrões relevantes em seu ambiente (HO *et al.* 2021).
- **Camada Intermediária:** As camadas intermediárias em uma rede neural, apesar de não interagirem diretamente com o ambiente externo, têm uma influência significativa no funcionamento da rede. Uma camada intermediária com poucos neurônios pode levar a um problema de underfitting, onde a rede não consegue detectar adequadamente os sinais em um conjunto de dados complicado. Por outro lado, uma camada intermediária com muitos neurônios pode levar a um problema de overfitting, onde a rede é treinada com muita informação limitada no conjunto de dados, tornando-a incapaz de generalizar para novos dados. É importante encontrar um

equilíbrio no número de neurônios na camada intermediária para garantir que a rede seja capaz de detectar padrões relevantes e generalizar adequadamente para novos dados. Além disso, muitos neurônios podem levar a problemas de treinamento inadequado em termos de tempo de processamento e recursos computacionais necessários para concluir o treinamento da rede de forma eficiente. Portanto, é importante ajustar adequadamente o número de neurônios na camada intermediária para garantir um treinamento eficaz e uma boa capacidade de generalização da rede (HO *et al.* 2021).

- **Camada de Saída:** A camada de saída é a última etapa do processo em uma rede neural e é responsável por retornar um padrão para o ambiente externo. O número de neurônios nesta camada está diretamente relacionado com a tarefa que a rede está executando. Em geral, para um classificador, o número de neurônios na camada de saída deve ser igual ao número de classes ou grupos distintos existentes no conjunto de dados que a rede está treinando. Esse número é importante porque cada neurônio na camada de saída representa uma classe ou grupo específico e, portanto, é responsável por prever se o padrão de entrada pertence a essa classe ou grupo. Além disso, o número de neurônios também pode afetar a precisão e eficácia da rede em tarefas de classificação, portanto, é importante selecioná-la cuidadosamente (HO *et al.* 2021).

5.1.3 Fase de Construção

Segundo o modelo unificado, essa fase envolve desenvolvimento/implementação do aplicativo DIAFOOT em sua totalidade. É a fase de construção de código e, conseqüentemente, geração dos componentes, os quais são integrados e testados (KRUCHTEN, 2013; SOMMERVILLE, 2011).

Para a construção do front-end, os protótipos das telas criados no Figma[®] durante a fase anterior serviram de norte para a confecção das telas do DIAFOOT e seus respectivos códigos. Essa confecção foi realizada por meio do editor de código *Visual Studio Code*, no qual foi usada a linguagem de programação *TypeScript*, variante do *JavaScript* que integra ao *JavaScript* tipagem estática durante a confecção das telas. Ainda, utilizou-se da biblioteca *React Native* para que o aplicativo tornasse multiplataforma e para que pudesse ser usado o *TypeScript* no desenvolvimento.

Para a implementação da rede feedforward foi utilizado o *Google Collaboratory*, simplesmente chamado de *Colab*, que é um serviço de nuvem gratuito hospedado pelo

próprio Google, e que serve para incentivar pesquisas de aprendizado de máquina (*machine learning*) e IA. O *Python* foi a linguagem usada para desenvolver a rede feedforward no *Google Collaboratory*, além dessas ferramentas, foi utilizado a biblioteca *Keras*, que é uma API de alto nível do *TensorFlow* para criar e treinar modelos de aprendizado profundo. Ela é usada para prototipagem rápida, pesquisa de ponta e produção. O *TensorFlow* é uma biblioteca de código aberto criada para aprendizado de máquina, computação numérica e muitas outras tarefas. Foi desenvolvido pelo Google em 2015 e rapidamente se tornou uma das principais ferramentas para *machine learning* e *deep learning*

Após a modelagem do banco de dados, partiu-se para a criação do mesmo usando, para isto, o *Firestore Realtime Database*, que é hospedado na servidor externo. Ele permite também sincronizar em tempo real os dados armazenados, do tipo *JSON*, entre os usuários do aplicativo, o *JSON* é um formato de dados baseado em chave-valor, a chave é no formato de cadeia de caracteres e seu valor associado pode ser tipos primitivos.

5.1.4 Fase de Transição

O propósito desta fase é fazer a transição do sistema do ambiente de desenvolvimento para o ambiente real. São feitos testes de sistema e de aceitação e a entrega do sistema aos seus usuários.

Diante exposto e com a finalização da fase de construção, o projeto do aplicativo DIAFOOT foi colocado para o teste de sistema e de aceitação a fim de encontrar algumas inconsistências no código e de verificar se o aplicativo atendeu aos requisitos propostos.

5.1.5 Atividades

Cada fase do PU, por sua vez, pode compreender um número arbitrário de iterações, isto dependerá das características de cada projeto. Além disto, todo o conjunto de fases também pode ser realizado em ciclos, ou seja, de maneira incremental.

Durante o ciclo de vida do projeto DIAFOOT, as atividades foram distribuídas ao longo de uma iteração, em função do foco da fase correspondente. Por exemplo, na iteração que ocorreu no final da fase de elaboração, tipicamente realizaram-se atividades de especificação de requisitos, análise, projeto, implementação e testes. Já, a interação ocorrida na fase de concepção, essencialmente foram efetuadas novas atividades de levantamento de requisitos, com algum trabalho de modelagem (análise).

6 RESULTADOS E DISCUSSÕES

6.1 Implementação da RNA Profunda

Para estruturação do sistema foi necessário a utilização da RNA, desenvolvida por Mesquita (2022), para a classificação das coberturas a serem aplicadas na lesão do pé diabético. Essa RNA teve sua arquitetura estruturada em três camadas densas, distribuídas em camada de entrada, camada oculta e camada de saída (Tabela 1). Tanto a camada de entrada quanto a camada oculta foram compostas por quatro neurônios, com função de ativação ReLU. Já a camada de saída apresentou dezesseis neurônios, os quais empregaram a SoftMax como função de ativação (MESQUITA, 2022).

Tabela 1 - Distribuição das camadas densas.

Camada (Tipo)	Forma de saída	Parâmetro
Dense_1 (Entrada das informações)	4	24
Dense_1 (Oculta)	4	20
Dense_3 (Saída - Resposta esperada - Cobertura)	16	80

Parâmetros totais: 124

Parâmetros treináveis: 124

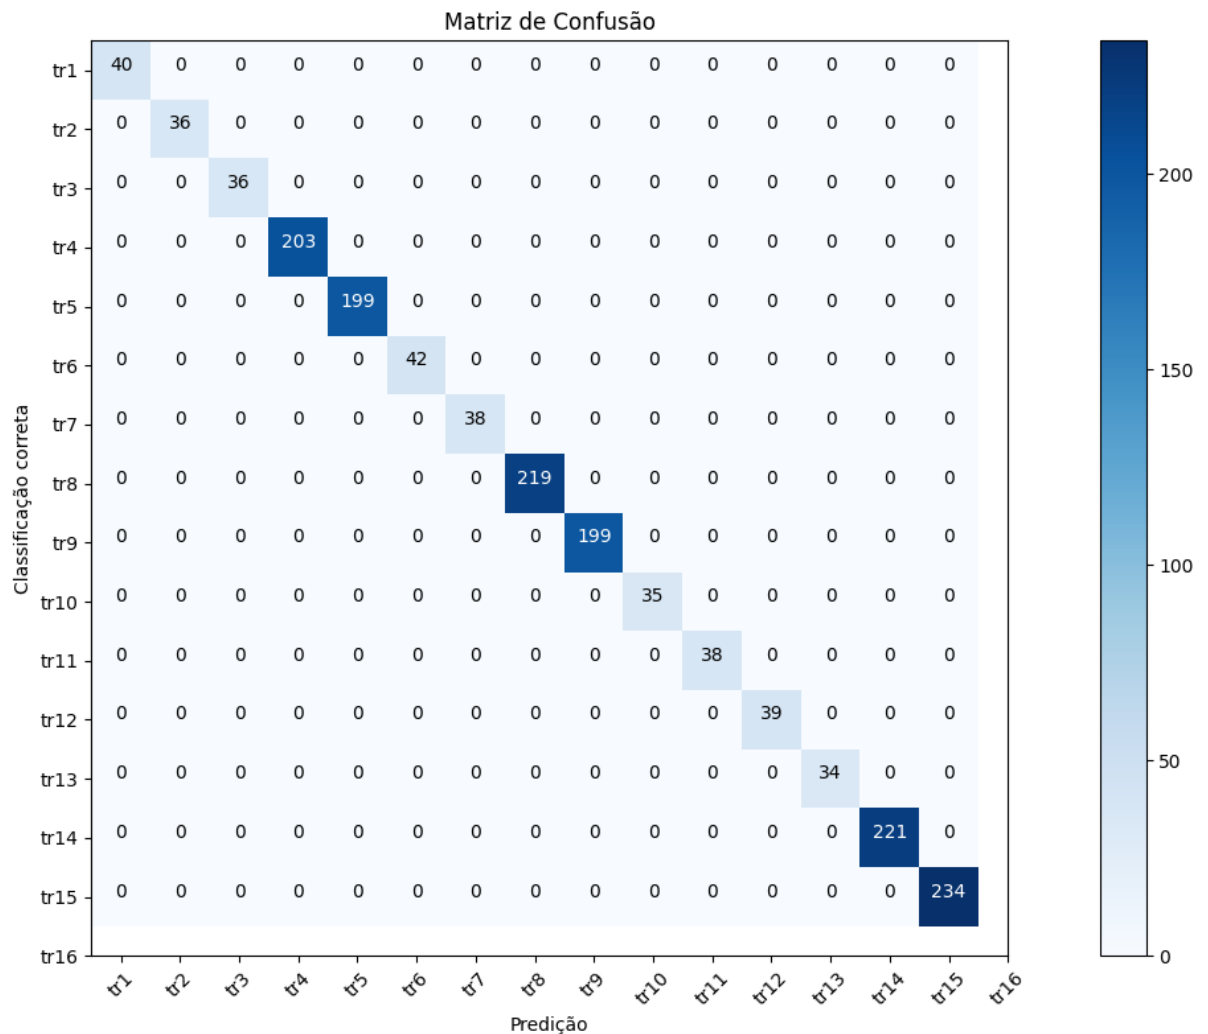
Parâmetros não-treináveis: 0

Fonte: MESQUITA (2022).

Após a estruturação da RNA, foram utilizados um total de 3.500 dados de entrada, que foram normalizados. Esses dados foram normalizados utilizando a técnica de *LabelEncoder*, onde ocorre um pré-processamento transformando as classes em valores numéricos inteiros, de 0 a $n\text{-classes}^{-1}$ dos quais 75% foram destinados à fase de treinamento da rede, enquanto os 25% restantes foram usados para a fase de teste, os parâmetros utilizados na rede foram informações retiradas do formulário do exame clínico da ferida (Figura 13, página 32), é importante ressaltar que foram utilizados apenas informações do formulário, a imagem do pé é utilizada apenas para histórico, sendo inclusive, opcional. Ao avaliar o desempenho da RNA na fase de teste, verificou-se que a mesma obteve uma taxa de acerto de 100%, conforme evidenciado na matriz de confusão da Figura 16, página 38. Na matriz, é possível observar que todos os valores estão localizados na diagonal principal, o que indica que a rede foi capaz de classificar corretamente todas as amostras de teste. Além disso, os valores em cada célula representam a quantidade de acertos para cada classe.

No código é utilizado a biblioteca *Keras* para criar e treinar um modelo de rede neural do tipo feedforward, com três camadas de neurônios. A primeira camada é uma camada de entrada com 4 neurônios, a segunda camada é uma camada oculta com 4 neurônios e função de ativação ReLU, e a terceira camada é uma camada de saída com 16 neurônios e função de ativação softmax. O modelo é compilado com o otimizador Adam e a função de perda *categorical_crossentropy*. O conjunto de dados é dividido em conjuntos de treinamento e teste, e o modelo é treinado em 100 épocas com um tamanho de lote de 10 exemplos. Após o treinamento, o modelo é avaliado e as previsões são geradas a partir do conjunto de testes. Uma matriz de confusão é gerada para avaliar o desempenho do modelo e dessa forma, podemos concluir que a RNA classificou corretamente todas as coberturas para os dados de entrada fornecidos.

Figura 16 - Matriz de confusão



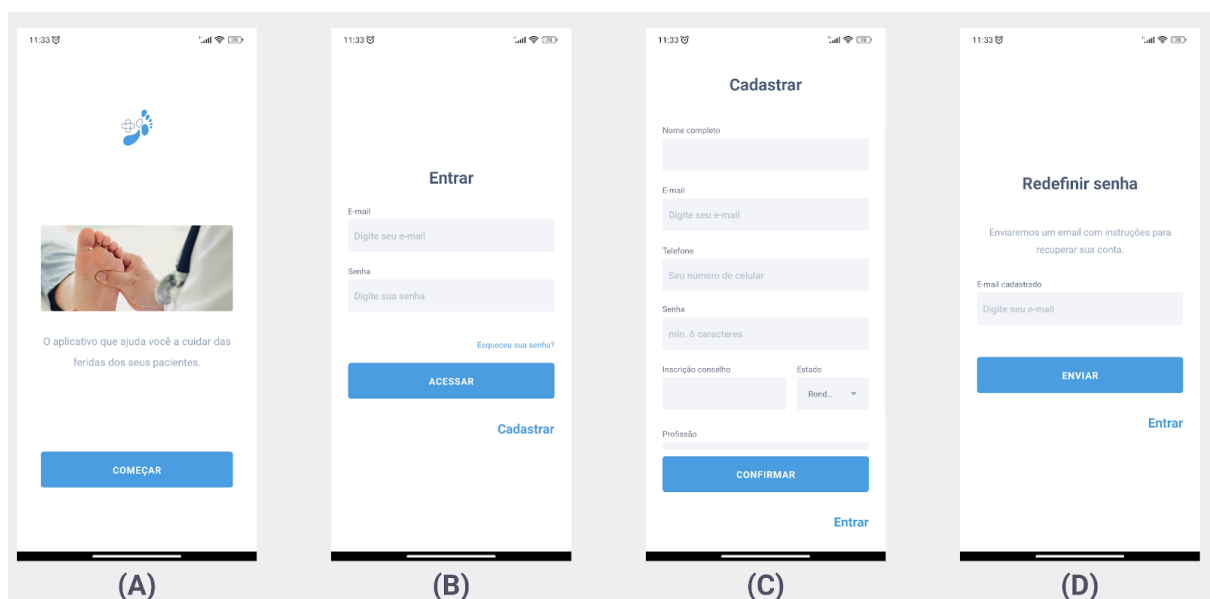
Fonte: Compilação do autor.

6.2 Construção do Aplicativo

Após a conclusão das prototipagens e a finalização da RNA, deu-se início à codificação da aplicação. Conforme os requisitos foram atualizados, algumas telas de formulários também sofreram modificações para melhor se alinharem aos casos de uso identificados.

As primeiras telas desenvolvidas foram a *splash screen* e as telas de autenticação. A *splash screen* é exibida somente uma vez ao usuário antes de realizar o cadastro na aplicação, conforme mostrado na Figura 17 (A). Já as telas de autenticação permitem que o usuário realize um cadastro para acessar as funcionalidades da aplicação, conforme mostrado na Figura 17 (C), seguindo para a tela de acesso às funcionalidades, como ilustrado na Figura 17 (B). Além disso, o usuário pode recuperar a senha fornecida durante o cadastro por meio do e-mail, como mostrado na Figura 17 (D).

Figura 17 - Telas de autenticação.

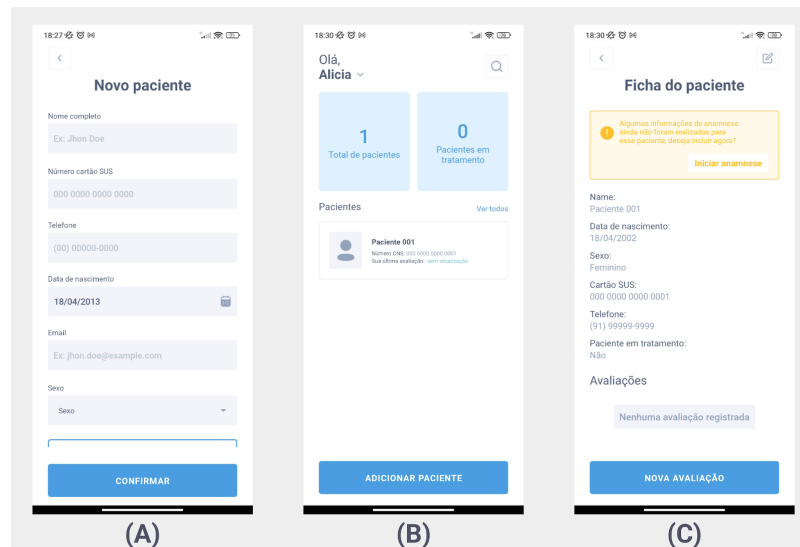


Fonte: Compilação do autor.

As próximas telas que foram desenvolvidas foram as relacionadas aos pacientes, incluindo telas de cadastro e listagem na aplicação. Para o cadastro do paciente, são coletados dados pessoais, como nome completo, número do cartão nacional do SUS (CNS), número de telefone, data de nascimento, entre outros, conforme ilustrado na Figura 18 (A), página 40. A precisão dessas informações é essencial para garantir a correta identificação do paciente e uma melhor gestão de seus dados médicos, como também mostrado na Figura 18 (B), página 40. Portanto, essas telas são cruciais para a eficiência e qualidade do atendimento prestado pelos profissionais da saúde. Na ficha do paciente, é possível realizar

uma avaliação clínica (Figura 18 (C), página 40), coletando dados que serão usados para acompanhamento do estado de saúde do paciente, além de consultar as avaliações já realizadas, avaliações que serão mostradas na Figura 19, página 40.

Figura 18 - Telas do paciente.



Fonte: Compilação do autor.

Na exibição das telas, torna-se possível visualizar a avaliação clínica do paciente, que consiste em um formulário informativo contendo informações sobre o histórico do paciente, conforme Figura 19. O formulário engloba dados como histórico pessoal (Figura 19 (A)), familiar (Figura 19 (B)), descrição da ferida (Figura 19 (C)) e exames físicos (Figura 19 (D)).

Dessa forma, a avaliação clínica se torna uma ferramenta importante para obter um panorama geral sobre a saúde do paciente, permitindo que o profissional da saúde possa traçar o melhor plano de tratamento e acompanhamento necessário.

Figura 19 - Telas do paciente - Anamnese.

The figure displays four sequential screens of a mobile application for patient anamnesis, labeled (A) through (D). Each screen is titled 'Avaliação clínica' and contains a progress indicator in the top right corner.

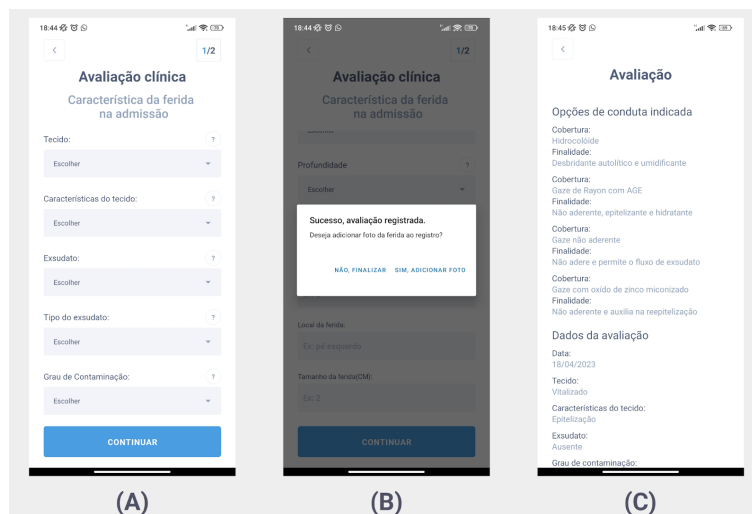
- (A) Antecedentes pessoais:** Shows a list of personal medical history items with checkboxes: Diabetes Mellitus, Hipertensão Arterial Sistêmica, Tabagismo, Etilismo, Neoplasia, Cardiopatia, Alergias, Cirurgias anteriores, and Outras doenças. Buttons: Cancelar, CONFIRMAR.
- (B) Antecedentes familiares:** Shows a list of family medical history items with checkboxes: Diabete mellitus, Hipertensão Arterial Sistêmica, Neoplasia, Cardiopatia, Pneumopatias, and Outras doenças. Buttons: Voltar, CONFIRMAR.
- (C) História da ferida:** Shows wound history information: Primeira incidência (18/04/2023), Etiologia (dropdown menu), and Recidivada (checkbox). Buttons: Voltar, CONFIRMAR.
- (D) Exame físico:** Shows physical exam data: Programa de Benefício de Medicamento, Pressão arterial (mmHg), Peso (kg), Temperatura (°C), Incurções respiratórias por minuto (mm), and Índice de massa corporea. Buttons: Voltar, CONFIRMAR.

Fonte: Compilação do autor.

Torna-se possível verificar a captura das características da ferida. O formulário consiste em duas etapas: na primeira, são inseridas as informações da ferida (Figura 20 (A)), na segunda e última etapa, é capturada uma imagem que serve de registro histórico para as informações anteriores e para a própria ferida do paciente (Figura 20 (B)).

A seguir, é exibida uma tela que mostra a classificação das feridas com base em um modelo de aprendizado de máquina já treinado e integrado à aplicação (Figura 20 (C)). É nesta etapa que ocorre o processamento dos dados fornecidos pelo formulário em conjunto com a rede neural, resultando em sugestões para o tratamento das feridas. As próximas imagens mostram o processo de classificação e interpretação, que se baseia no modelo de RNA previamente treinado e integrado à aplicação. Com essas informações, a rede fornece sugestões de cobertura e tratamento para as lesões por meio de modelagem.

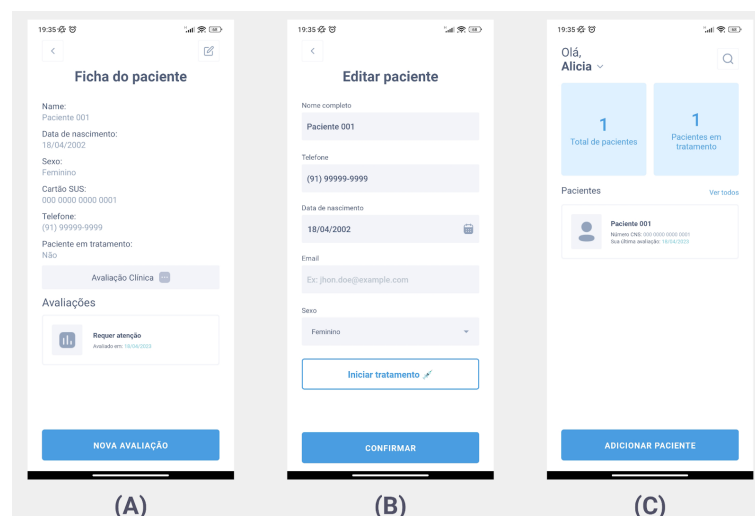
Figura 20 - Telas do paciente - Classificação e Interpretação.



Fonte: Compilação do autor.

Na figura a seguir, verifica-se que na ficha do paciente estão disponíveis informações da anamnese e das avaliações realizadas, conforme apresentado na Figura 21 (A), página 42. Essas informações são importantes para que o paciente possa ser atribuído a um profissional e iniciar o tratamento necessário, utilizando a funcionalidade 'iniciar tratamento', mostrado na Figura 21 (B), página 42. Essa funcionalidade pode ser encontrada na tela principal da aplicação, que apresenta dois cartões distintos: um que exibe a quantidade de pacientes cadastrados na base de dados e outro que mostra os pacientes que estão em tratamento para aquele usuário/profissional (Figura 21 (C), página 42).

Figura 21 - Telas do paciente - Informações.



Fonte: Compilação do autor.

7 CONCLUSÃO

Este trabalho teve como objetivo desenvolver uma rede neural integrada em um aplicativo para ajudar a automatizar o processo de exame da ferida do pé diabético e gerar recomendações assertivas de condutas para um tratamento eficaz. Durante o desenvolvimento, foram enfrentadas algumas dificuldades, como a pandemia, mudanças de escopo e contratempos na integração da rede com o aplicativo. No entanto, a rede teve um desempenho considerado excelente, atingindo 100% de acurácia na classificação dos casos de pé diabético. A integração da rede ao aplicativo tornou seu uso amigável e agregou valor a quem irá utilizá-lo.

O aplicativo desenvolvido apresentou uma abordagem para a recomendação de condutas em casos de pé diabético, permitindo a coleta de características da ferida do paciente e processá-las em uma rede para classificação. Com isso, o aplicativo apresentou uma alternativa para a tomada de decisões clínicas baseada em evidências, contribuindo para aprimorar a qualidade do atendimento aos pacientes com pé diabético e para aperfeiçoar os métodos de diagnóstico e tratamento da doença.

O uso do aplicativo pode ajudar os profissionais de saúde a melhorar a eficácia da recomendação de condutas para pacientes com pé diabético, permitindo a identificação mais precisa do tipo de ferida e do grau de gravidade da condição do paciente, o que pode ajudar a garantir uma intervenção adequada e evitar complicações. Além disso, o uso do aplicativo pode contribuir para a redução de erros e para a melhoria da segurança do paciente.

Apesar de a aplicação possuir algumas limitações, como a necessidade de validação clínica em larga escala e a dependência da precisão da coleta de dados por parte dos profissionais da saúde, o estudo pode servir de base para futuras pesquisas em áreas como inteligência artificial e análise de dados para aprimorar a efetividade do diagnóstico e tratamento de doenças crônicas. Torna-se importante ressaltar que o aplicativo foi desenvolvido com base em evidências clínicas existentes e sua eficácia deve ser validada em um número maior de pacientes para garantir sua segurança.

A abordagem utilizada no desenvolvimento do aplicativo pode ser aplicada em outras áreas da saúde, como a dermatologia ou a oncologia. Um trabalho futuro poderia explorar essa possibilidade e avaliar os benefícios dessa abordagem em outras áreas da saúde. O desenvolvimento de tecnologias para o diagnóstico e tratamento de doenças crônicas, como o pé diabético, é uma questão importante para a saúde pública. O aplicativo pode trazer benefícios significativos para a sociedade, como a redução de custos com tratamentos

ineficazes ou desnecessários, à melhoria da qualidade de vida dos pacientes com a doença e a diminuição da incidência de amputações relacionadas ao pé diabético.

REFERÊNCIAS

- ALEXIADOU, K; DOUPIS, J. Management of diabetic foot ulcers. *Diabetes Therapy*, v. 3, p. 1-15, 2012.
- ARAÚJO, L. F. Uma abordagem baseada em redes neurais artificiais para diagnóstico de diabetes. 2021.
- BISONG, E. Google colaboratory. Building machine learning and deep learning models on google cloud platform: a comprehensive guide for beginners, p. 59-64, 2019.
- BRAGA, A. V. et al. Inteligência artificial na medicina. *CIPEEX*, v. 2, p. 937-941, 2018.
- BRASILEIRO, J. L. et al. Pé diabético: aspectos clínicos. *Jornal vascular brasileiro*, v. 4, n. 1, p. 11-21, 2019.
- BURIHAN, M. C; JÚNIOR, W. C. Consenso no tratamento e prevenção do pé diabético. *SBACV-SP, Brasil*, p. 1-76, 2020.
- CONSULTING, V. W. *mHealth for development: the opportunity of mobile technology for healthcare in the developing world*. Washington Dc and Berkshire, UK, 2009.
- CORREIA, R. D. et al. Nutrimobile: um sistema de avaliação do estado nutricional de pacientes hospitalizados para dispositivos móveis. *Revista Brasileira de Inovação Tecnológica em Saúde-ISSN: 2236-1103*, 2013.
- FARIAS, J. L. C. B. Controle inteligente para um pâncreas artificial utilizando redes neurais artificiais. 2021. Dissertação de Mestrado. Universidade Federal do Rio Grande do Norte.
- FORTI, A. C. et al. Diretrizes da Sociedade Brasileira de Diabetes (SBD). *Diretrizes da Sociedade Brasileira de Diabetes*, v. 2020, n. 2019, p. 491, 2019.
- HAYKIN, S. *Redes neurais: princípios e prática*. Bookman Editora, 2001.
- HO, L. Vet al. A hybrid computational intelligence approach for structural damage detection using marine predator algorithm and feedforward neural networks. *Computers & Structures*, v. 252, p. 106568, 2021.
- KERAS. Tensor Flow. Disponível em: <https://www.tensorflow.org/guide/keras?hl=pt-br>. Acesso em: 30 abr. 2023.
- KOLB, J. "teste-300 x 73 Fases do Processo Unificado." *Compartilhando*, 15 Dezembro 2013. Disponível em: <https://jkolb.com.br/fases-do-processo-unificado/>. Acesso em: 20 abr. 2023.
- KOVÁCS, Z. L. *Redes neurais artificiais*. Editora Livraria da Física, 2002.
- KRUCHTEN, P. Contextualizing agile software development. *Journal of software: Evolution and Process*, v. 25, n. 4, p. 351-361, 2013.

MANSOOR, H. et al. Diabetic corneal neuropathy. *Journal of Clinical Medicine*, v. 9, n. 12, p. 3956, 2020.

MARINHO, T. L. et al. Assistente inteligente para auxiliar na prevenção do diabetes Tipo 2. In: *Anais Estendidos do XIX Simpósio Brasileiro de Computação SEMI Aplicada à Saúde*. SBC, 2019. p. 121-126.

MESQUITA, S. K. C. Redes neurais artificiais para auxílio aos enfermeiros na tomada de decisão sobre coberturas para lesões venosas. 2022.

MIRANDA, F. A.; DE FREITAS, S. R. C.; FAGGION, P. L. Integração e interpolação de dados de anomalias ao ar livre utilizando-se a técnica de RNA e krigagem. *Boletim de Ciências Geodésicas*, v. 15, n. 3, p. 428-443, 2009.

MOHSENI-MOGHADDAM, P.; GHOBADIAN, R.; KHALEGHZADEH-AHANGAR, H. Dementia in Diabetes mellitus and Atherosclerosis; Two Interrelated Systemic Diseases. *Brain research bulletin*, 2022.

NORVIG, P.; RUSSELL, S. Inteligência artificial. Rio de Janeiro: Grupo GEN, 2013.

O QUE É TENSORFLOW? Para que serve na prática? *Didática Tech*. Disponível em: <https://didatica.tech/o-que-e-tensorflow-para-que-serve/>. Acesso em: 30 abr. 2023.

OCHOA-VIGO, K.; PACE, A. E. Pé diabético: estratégias para prevenção. *Acta paulista de Enfermagem*, v. 18, p. 100-109, 2005.

PERRIN, P. B.; PIERCE, B. S.; ELLIOTT, T. R. COVID-19 and telemedicine: A revolution in healthcare delivery is at hand. *Health science reports*, v. 3, n. 2, 2020.

PONTI, M. A.; DA COSTA, G. B. P. Como funciona o deep learning. *arXiv preprint arXiv:1806.07908*, 2018.

PRESSMAN, R. S.; MAXIM, B. R. Engenharia de software-9. McGraw Hill Brasil, 2021.

REDE NEURAL ARTIFICIAL - Blocos de Construção. Disponível em: <https://tutoriais.edu.lat/pub/artificial-neural-network/artificial-neural-network-building-blocks/rede-neural-artificial-blocos-de-construcao>. Acesso em: 22 nov. 2022.

REDES NEURAS ARTIFICIAIS: criando um Perceptron de uma camada. *Growiz*, 30 October 2020. Disponível em: <https://growiz.com.br/redes-neurais-artificiais-criando-um-perceptron-de-uma-camada-em-c/>. Acesso em: 22 nov. 2022.

RIZZO, I. V.; CANATO, R. L. C. Inteligência artificial: funções de ativação. *Prospectus* (ISSN: 2674-8576), v. 2, n. 2, 2020.

RUP - Rational Unified Process - Desenvolvimento de Softwares. *InfoEscola*. Disponível em: <https://www.infoescola.com/engenharia-de-software/rup/>. Acesso em 11 jan. 2023.

SALOMÉ, G. M.; BLANES, L.; FERREIRA, L. M. Avaliação de sintomas depressivos em pessoas com diabetes mellitus e pé ulcerado. *Revista do Colégio Brasileiro de Cirurgiões*, v. 38, p. 327-333, 2011.

SCHMIDT-HIEBER, J. Nonparametric regression using deep neural networks with ReLU activation function. 2020.

SERRA, L. M. A.. Pé diabético: manual para a prevenção da catástrofe. Lidel, 2008.

SILVA, R. N. et al. Identificação de Pacientes Diabéticos com Potencial para Desenvolver o Pé Diabético (2014).

SINGH, N; ARMSTRONG, D. G.; LIPSKY, B. A. Preventing foot ulcers in patients with diabetes. *Jama*, v. 293, n. 2, p. 217-228, 2005.

SOMMERVILLE, I. Engenharia de Software-8ª Edição 2007. Ed Person Education, 2011.

SUN, H et al. IDF Diabetes Atlas: Global, regional and country-level diabetes prevalence estimates for 2021 and projections for 2045. *Diabetes research and clinical practice*, v. 183, p. 109119, 2022.

TISSOT, H. C.; CAMARGO, L. C.; POZO, A. T. R. Treinamento de redes neurais feedforward: comparativo dos algoritmos backpropagation e differential evolution. In: *Brazilian Conference on Intelligent Systems*. 2012.

TORTORA, G. J.; DERRICKSON, B. H. Principles of anatomy and physiology. John Wiley & Sons, 2018.

TOSCANO, C. M. et al. Annual direct medical costs of diabetic foot disease in Brazil: a cost of illness study. *International journal of environmental research and public health*, v. 15, n. 1, p. 89, 2018.

TSUI, F; DUGGINS, S; KARAM, O. Software protection with increased complexity and obfuscation. In: *Proceedings of the 50th Annual Southeast Regional Conference*. 2012. p. 341-342.

WORLD HEALTH ORGANIZATION et al. mHealth: new horizons for health through mobile technologies. *mHealth: new horizons for health through mobile technologies.*, 2011.

YABUKE A. T: Modelo Preditivo Eficiente Para Análise e Detecção de Pessoas com Diabetes. 2021.