



UNIVERSIDADE DE BRASÍLIA – UNB

CAMPUS GAMA – FGA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA BIOMÉDICA

**APRENDIZADO DE MÁQUINA PARA AUTOMATIZAÇÃO DE
CLASSIFICAÇÃO DE REGISTROS FOTOGRÁFICOS DE
ÚLCERAS DO PÉ DIABÉTICO (UPD) CONFORME A CLASSIFICAÇÃO
DA UNIVERSIDADE DO TEXAS**

THIAGO ALVES ESPINDOLA

ORIENTADORA: DRA. MARCELLA LEMOS BRETTAS CARNEIRO



UNIVERSIDADE DE BRASÍLIA – UNB
FACULDADE UNB GAMA – FGA



**APRENDIZADO DE MÁQUINA PARA AUTOMATIZAÇÃO DE CLASSIFICAÇÃO DE
REGISTROS FOTOGRÁFICOS DE ÚLCERAS DO PÉ DIABÉTICO (UPD)
CONFORME A CLASSIFICAÇÃO DA UNIVERSIDADE DO TEXAS**

THIAGO ALVES ESPINDOLA

ORIENTADORA: DRA. MARCELLA LEMOS BRETTAS CARNEIRO

**DISSERTAÇÃO DE MESTRADO EM
ENGENHARIA BIOMÉDICA**

**PUBLICAÇÃO: 154A/2022
BRASÍLIA/DF, SETEMBRO DE 2022**

UNIVERSIDADE DE BRASÍLIA - UNB
FACULDADE UNB GAMA - FGA
PROGRAMA DE PÓS-GRADUAÇÃO

**APRENDIZADO DE MÁQUINA PARA AUTOMATIZAÇÃO DE
CLASSIFICAÇÃO DE REGISTROS FOTOGRÁFICOS DE ÚLCERAS
DO PÉ DIABÉTICO (UPD) CONFORME A CLASSIFICAÇÃO DA
UNIVERSIDADE DO TEXAS**

THIAGO ALVES ESPINDOLA

Dissertação de mestrado submetida ao programa de pós-graduação em Engenharia Biomédica da Universidade de Brasília, como parte dos requisitos necessários para a obtenção do grau de mestre em Engenharia Biomédica.

Apresentada para:

Dra. Marcella Lemos Brettas Carneiro

(Orientadora/Presidente)

Dr. Cristiano Jacques Miosso

(Membro interno.)

Dra. Suélia de Siqueira Rodrigues Fleury Rosa

(Examinador interno/suplente)

Dr. José Carlos Tatmatsu Rocha

(Examinador externo)

Brasília/DF, setembro de 2022

Ficha Catalográfica

ESPINDOLA, THIAGO ALVES

Aprendizado de Máquina para automatização de classificação de registros fotográficos de Úlceras do Pé Diabético (UPD) conforme a Classificação da Universidade do Texas. [Distrito Federal], 2022. 61p., 210 x 297 mm (FGA/UnB Gama, Mestrado em Engenharia Biomédica, 2022).

Dissertação de Mestrado em Engenharia Biomédica, Faculdade UnB Gama, Programa de Pós-Graduação em Engenharia Biomédica.

- | | |
|----------------------------|--------------------|
| 1. Aprendizado de Máquina | 2. Cicatrização |
| 3. Inteligência Artificial | 4. Pé Diabético |
| I. FGA UnB | II. Título (série) |

Referência

Espindola, Thiago Alves (2022). Aprendizado de Máquina para automatização de classificação de registros fotográficos de Úlceras do Pé e Diabético (UPD) conforme a Classificação da Universidade do Texas. Dissertação de mestrado em Engenharia Biomédica, Publicação 154A/2022, Programa de Pós-Graduação em Engenharia Biomédica, Faculdade UnB Gama, Universidade de Brasília, Brasília, DF, 61p.

Cessão de Direitos

Autor: Thiago Alves Espindola

Título: Aprendizado de Máquina para automatização de classificação de registros fotográficos de Úlceras do Pé Diabético (UPD) conforme a Classificação da Universidade do Texas.

Grau: Mestre

Ano: 2022

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender essas cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta dissertação de mestrado pode ser reproduzida sem a autorização por escrito do autor.

thiagoaespindola@gmail.com

Brasília, DF – Brasil

Para a minha futura esposa, Samantha Florentino K. Samatta, com amor e carinho e minha enteada e filha Kennely Celine Samatta, a qual prometo dedicar toda atenção e amor que for possível.

AGRADECIMENTOS

Agradeço, primeiramente a Deus, pelas graças concedidas. A minha orientadora, Marcella Lemos Brettas Carneiro, por sua imensa paciência, persistência e sabedoria compartilhada, sem o qual o estudo não seria possível. Da mesma forma, ao professor Cristiano Jacques Miosso Rodrigues Mendes, que prestou todo o apoio necessário a concepção do trabalho. Minha profunda gratidão e admiração a professora Suélia de Siqueira Rodrigues Fleury Rosa, que acreditou na minha capacidade me acolheu no programa de pós-graduação. Mais que uma profissional dotada de excepcional saber e competência, uma educadora em sentido amplo. Sem a sua ajuda, jamais teria chegado até aqui.

Agradeço especialmente ao meu irmão de batalha Leonardo Alves Costa, por todo auxílio, apoio e tempo dedicado, imensurável em poucas linhas. Da mesma forma, a minha Família, em especial, ao meu irmão Hiago Matheus da Silva, que, com sua companhia, me fortalece diariamente. Por fim, aos meus companheiros de jornada, Luciene Ferreira dos Anjos, Luzia Sousa Ferreira e Rian Sousa Florentino das Chagas, que estiveram ao meu lado em todos os momentos.

RESUMO

Introdução: A Úlcera de Pé Diabético (UPD) é uma complicação da diabetes e é caracterizada por apresentar feridas associadas a isquemia, neuropatia e deformidades a qual pode levar à amputação. Neste contexto, classificar a ferida consiste em avaliar a lesão e identificar o grau de comprometimento das estruturas teciduais e com base nessa análise, categorizar em uma escala padronizada. Tem como papel orientar o diagnóstico para estabelecer a cobertura adequada a cada ferida, além do registro da evolução da úlcera e, por fim, garantir que qualquer profissional de saúde possa entender o estado clínico dando continuidade ao tratamento. **Objetivo:** Desenvolver um algoritmo para automatizar o processo de classificação de UPD a partir de registros fotográficos de úlceras, utilizando a Classificação da Universidade do Texas. **Metodologia:** A escrita do algoritmo foi realizada na linguagem Python, uma vez que possui suporte à Inteligência Artificial (IA). Foi selecionada a técnica Redes Neurais Convolucionais (CNNs) por possibilitar o aprendizado com a utilização de amostras. O universo amostral foi composto por 554 registros UPD obtidas no ensaio clínico do projeto RAPHA®. **Resultados:** Obteve-se um produto de inovação tecnológica: uma ferramenta para treinamento e classificação que pode ser efetuado por profissionais não especializados em *Machine Learning*. Denominado Claucia - acrônimo para “Classificação de úlceras com Inteligência Artificial”, a versão inicial foi testada por profissionais de saúde (onde foi cedido os registros de UPD para que as classificassem e após esse processo, foi instalado o programa para comparação dos resultados, tendo o software acurácia elevada. Contudo, observou-se também que houve *overfitting* (problema relacionado as fases de treinamento, onde ao receber dados novos, o modelo de aprendizado não consegue aplicar corretamente as regras de classificação). Isso devido ao volume insuficiente de amostras utilizadas em face da complexidade exigida pela rede e também por não ter amostras de todas as classes. Nesse contexto, o estudo não se encerra no desenvolvimento da ferramenta apresentada, mas deixa em aberto possibilidades de continuidade em novos trabalhos, com acréscimo de amostragem e aplicação de outras métricas de qualidade, como precisão e sensibilidade.

Palavras-chave: Aprendizado de Máquina, Cicatrização, Inteligência Artificial, classificador, Úlceras de Pé Diabético.

ABSTRACT

Introduction: Diabetic Foot Ulcer (DUP) is a complication of diabetes and is characterized by wounds associated with ischemia, neuropathy and deformities which can lead to amputation. In this context, classifying the wound consists of evaluating the lesion and identifying the degree of involvement of tissue structures and, based on this analysis, categorizing it on a standardized scale. Its role is to guide the diagnosis to establish adequate coverage for each wound, in addition to recording the evolution of the ulcer and, finally, to ensure that any health professional can understand the clinical status, continuing the treatment. **Objective:** To develop an algorithm to automate the UPD classification process from photographic records of ulcers, using the University of Texas Classification. **Methodology:** The algorithm was written in the Python language, since it supports Artificial Intelligence (AI). The Convolutional Neural Networks (CNNs) technique was selected because it allows learning with the use of samples. The sample universe consisted of 554 UPD records obtained in the clinical trial of the RAPHA® project. **Results:** A product of technological innovation was obtained: a tool for training and classification that can be performed by professionals not specialized in Machine Learning. Called Claucia - acronym for "Classification of ulcers with Artificial Intelligence", the initial version was tested by health professionals (where the UPD records were provided for them to classify them and after this process, the program was installed to compare the results, having the software high accuracy. However, it was also observed that there was overfitting (a problem related to the training phases, where when receiving new data, the learning model cannot correctly apply the classification rules). This is due to the insufficient volume of samples used given the complexity required by the network and also for not having samples of all classes. In this context, the study does not end with the development of the tool presented, but leaves open possibilities for continuity in new works, with the addition of sampling and application of other quality metrics, such as precision and sensitivity.

Keywords: Machine Learning, Healing, Artificial Intelligence, Director, Diabetic Foot Ulcers.

Sumário

1.	INTRODUÇÃO.....	13
1.1	Objetivos	15
1.1.1	Geral	15
1.1.2	Específicos	15
1.2	Justificativa.....	16
2.	FUNDAMENTAÇÃO TEÓRICA	17
2.1	Pé Diabético	17
2.2	Sistema terapêutico para neoformação tecidual - RAPHA®	19
2.3	Avaliação de feridas	21
2.4	Classificação das feridas conforme a Universidade do Texas	22
2.5	Inteligência Artificial.....	24
2.5.1	Aprendizado de máquina.....	26
2.5.2	Redes neurais artificiais	27
3.	MATERIAL E MÉTODOS	29
3.1	Estudo clínico: caracterização da amostra	29
3.2	Desenvolvimento do algoritmo de classificação de imagens.....	32
3.3	Desenvolvimento do algoritmo de classificação	35
3.3.1	Execução do algoritmo	37
4.	RESULTADOS E DISCUSSÃO	39
4.1	Finalização do algoritmo.....	39
4.2	Testes de funcionamento e acurácia.....	42
5.	CONCLUSÃO	50
5.1	Trabalhos futuros	51
6.	REFERÊNCIAS BIBLIOGRÁFICAS	53
7.	ANEXO I – Certificado de registro de programa de computador.	61

LISTA DE TABELAS

Tabela 1. Sinais e sintomas dos tipos de Pé Neuropático e Pé Isquêmico.....	18
Tabela 2. Classificação de Ferida Diabética da Universidade do Texas.....	24
Tabela 3. Aplicativos para smartphones destinados ao monitoramento e prevenção de úlcera de pé diabético.	46
Tabela 4. Estudos de segmentação relacionados à análise de imagens de feridas.	47
Tabela 5. Lista de estudos que sobre o uso de Aprendizado de Máquina para Úlceras de Pé Diabético.	48

LISTA DE FIGURAS

Figura 1. Sistema terapêutico para neoformação tecidual RAPHA®.	21
Figura 2. Método de medição tradicional da ferida.....	22
Figura 3. Organograma da metodologia adotada por este estudo.	29
Figura 4. Organização da execução do ensaio clínico..	31
Figura 5. Exemplo de amostras utilizadas.....	33
Figura 6. Organização das imagens em pastas seguindo a classificação da Universidade do Texas.....	34
Figura 7. Linhas de código responsável pela importação das imagens para o algoritmo iniciar o treinamento.	35
Figura 8. Modelo esquemático do funcionamento do Aprendizado de Máquina, dividindo o em fases de processamento (com adaptações).....	36
Figura 9. Lógica para o comportamento do classificador.	37
Figura 10. Exemplo da sequência de instruções que o algoritmo (programa) deve executar.....	40
Figura 11. Interface de usuário do sistema de classificação de feridas usando inteligência artificial.	41
Figura 12. Passo a passo para uso do programa.....	42
Figura 13. Métricas de desempenho do Aprendizado de Máquina: Relatório gerado pelo sistema..	44
Figura 14. Exemplo de imagem de úlcera com segmentação, com adaptações.....	47

LISTA DE NOMENCLATURAS E ABREVIações

AM	Aprendizado de Máquina, do inglês <i>Machine Learning</i>
Bireme	Centro Latino-Americano e do Caribe de Informação em Ciências da Saúde
BLN	Biomembranas de Látex Natural
DAP	Doença Arterial Periférica
DM	Diabetes Mellitus
FAPESP	Fundação de Amparo à Pesquisa de São Paulo
IA	Inteligência Artificial
IHQ	Imuno-Histoquímica
LED	Light Emitting Diode
MCP	Neurônio McCulloch e Pitts
MS	Ministério da Saúde
RNA	Redes Neurais Artificiais
SAPS	Serviços de Atenção Primária
SciELO	Scientific Electronic Library Online
SINBAD	Bacterial infection, Area and Depth
SUS	Sistema Único de Saúde
UnB	Universidade de Brasília
UPD	Úlceras do Pé Diabético
Wifi	<i>Wound, Ischemia, Foot Infection</i>

1. INTRODUÇÃO

A Diabetes Mellitus (DM) é uma doença crônica não transmissível, caracterizada pelo aumento da glicose plasmática (hiperglicemia) devido a defeitos na ação ou secreção de insulina (SBD, 2014). Esta doença possui podem ser classificadas como tipo 1 (produção de insulina é insuficiente) e tipo 2 (caracterizada por resistência à ação da insulina), como consequência, há destruição imune das células beta pancreáticas além desses tipos, também há à DM gestacional, decorrente de alterações dos níveis de glicose durante a gestação. Por fim, há também outros tipos específicos de DM de origem genética, por falha nas células beta, na ação da insulina, no pâncreas exócrino e até mesmo devido a infecções (BERTONHI, 2018).

Atualmente, a DM é considerada pelas autoridades de saúde como um sério problema de saúde pública. Este fato está associado à elevada incidência de morbimortalidade e alto índice de complicações que impactam economicamente, fisicamente e psicologicamente os portadores desta moléstia (THOMAS *et al.*, 2019).

O Brasil consta como o quinto país com maior de incidência de diabetes no mundo, perdendo apenas para China, Índia, Estados Unidos e Paquistão. Em 2020, foram registrados aproximadamente 463 milhões de portadores, com a prevalência da faixa etária entre 20 e 79 anos (EGLE, 2021).

No ano anterior, 2019, o Serviço de Atenção Primária em Saúde, Atendimentos nos Serviços de Atenção Primária (SAPS),¹ chegou a registrar 11 milhões de consultas somente para pessoas acometidas por essa doença, com o número por volta de 136 mil internações. Isso gerou gastos na ordem de R\$ 98 milhões aos cofres públicos (BRASIL, 2020). O que coloca o Brasil entre os países com maiores gastos com tratamento de Diabetes (THOMAS *et al.*, 2019).

Dentre as complicações de maior incidência da DM estão as Úlceras do Pé Diabético (UPD). Entende-se por Pé Diabético ou UPD a presença de infecção, ulceração ou destruição de tecidos profundos associados a anormalidades

¹ Primeiro nível de Atenção Básica, é caracterizado por um conjunto de ações, no âmbito individual e coletivo, para a promoção da saúde, prevenção de agravos, diagnóstico, tratamento, reabilitação, redução de danos e a manutenção da saúde. De tal modo, é a principal porta de entrada do Sistema Único de Saúde (SUS) e do centro de comunicação com toda a Rede de Atenção dos SUS, devendo se orientar pelos princípios da universalidade, da acessibilidade, da continuidade do cuidado, da integralidade da atenção, da responsabilização, da humanização e da equidade (BRASIL, 2021).

neurológicas e a vários graus de doença vascular periférica em pessoas com DM. Tais alterações na massa muscular e anatomia óssea dos pés causam pontos de pressão, ao mesmo tempo em que o ressecamento da pele prejudica a elasticidade protetora cutânea e a circulação (BRASIL, 2018).

De tal modo, o Pé Diabético é responsável por um alto índice de casos que evoluem para amputação dos membros inferiores, chegando em torno de 20%, com uma média de 42 mil amputações anuais (JORGE, 2020).

Dada a gravidade desta enfermidade e seus elevados custos associados, novas tecnologias e terapias vêm sendo desenvolvidas para acelerar o processo natural de cicatrização e reduzir a quantidade de atendimentos e gastos nos serviços públicos de saúde. Neste contexto, surgiu o projeto RAPHA®, que significa cura em hebraico. Este projeto foi desenvolvido na Universidade de Brasília (UnB) e consiste na avaliação terapêutica da associação de fototerapia, por meio de uso de equipamento diodo emissor de luz (*Light Emitting Diode* - LED) e curativo baseado em biomembranas de látex natural obtido de *Hevea brasiliensis*. Os ensaios clínicos iniciaram-se em 2013 e foram finalizados em 2019.

Ressalta-se que é muito importante diagnosticar e tratar adequadamente uma úlcera. Sobretudo, destaca-se que uma avaliação correta permite, por exemplo, identificar possíveis causas do ferimento, avaliar a resposta proliferativa e estimar o surgimento de novas lesões, dentre outros. Contudo, é um grande desafio fazer uma avaliação correta visto que a cicatrização é um processo dinâmico e regulado por complexos mecanismos fisiopatológicos (GARBUIO *et al.*, 2018). Além disso, fatores subjetivos à avaliação como experiência clínica do avaliador e tipos de instrumentos de medidas utilizados são fatores que podem resultar em interpretações divergentes quando a avaliação é realizada por diferentes locais e por diferentes profissionais (FAVRETO *et al.*, 2017).

Atualmente, a forma mais comum de avaliação de feridas crônicas consiste na identificação visual do tecido danificado a partir de cores dominantes, como vermelho-amarelo-preto e realização de medições e descrições das características como área, bordas, profundidade entre outras (CUNHA; DUTRA; SALOMÉ, 2018). As dimensões são obtidas por meio de medição com régua graduada em centímetros ou com o

contato direto da lesão com papel vegetal transparente, sendo o papel imediatamente descartado após aferir o tamanho da ferida (DA SILVA *et al.*, 2016).

A avaliação da ferida considera aspectos fisiológicos da ferida, tais como tamanho, presença de infecção entre outros. Tais informações servem de base para classificação, padronizada e adotada nacionalmente, onde cada categoria da classe sintetiza o estado ulcerativo, a fim que se registre de forma clara todos os estados ulcerativos do tratamento. Atualmente o Ministério da Saúde adota a classificação denominada “Classificação da Universidade do Texas”(SBD, 2014).

Nesse sentido, métodos de processamento digital de sinais e imagens podem apresentar um impacto positivo para a avaliação da evolução de feridas entre as sessões de tratamento ou entre um protocolo e outro. Assim, é importante realizar análises com precisão, que sejam passíveis de reprodução e posteriores reavaliações. Por meio de Inteligência Artificial (IA) é possível determinar os possíveis caminhos para a classificação como o uso de algoritmo que têm seus parâmetros ajustados em procedimentos denominados treinamento. Este conhecimento pode ser aplicado em diversas aplicações na área biomédica, incluindo sistemas de classificação e predição (KAPLAN; HAENLEIN, 2019).

Este estudo visa criar uma ferramenta de inovação tecnológica capaz de automatizar o processo de reconhecimento e classificação de UPD, a partir de registros fotográficos de úlceras, utilizando-se técnicas de Aprendizado de Máquina e baseado na classificação adotada pelo Ministério da Saúde.

1.1 Objetivos

1.1.1 Geral

Desenvolver um algoritmo para classificar úlceras conforme a Classificação da Universidade do Texas por meio de registros fotográficos.

1.1.2 Específicos

- Desenvolver um algoritmo para automatizar o processo de reconhecimento e classificação de úlceras a partir de registros fotográficos;

- Executar testes de execução e acurácia, para as devidas correções a fim de que a resposta dada pelo sistema seja equivalente à classificação real;
- Codificar interface gráfica para interação do usuário com a funcionalidade de classificação;
- Verificar a porcentagem de assertividade da identificação realizada pelo algoritmo, por meio da métrica de acurácia.

1.2 Justificativa

A análise de feridas, por processamento digital, consiste em um importante recurso para avaliação da evolução de feridas entre as sessões de tratamento ou entre um protocolo e outro. Assim, é importante realizar análises com precisão, que sejam passíveis de reprodução e posteriores reavaliações. Assim, neste estudo foi criado um algoritmo para automatizar o processo de reconhecimento e classificação de UPD a partir de registros fotográficos de úlceras utilizando-se técnicas de Aprendizado de Máquina.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 Pé Diabético

Denomina-se Pé Diabético, ou UPD, uma ulceração com presença de infecção e/ou destruição de tecidos profundos associados a anormalidades neurológicas e a vários graus de doença vascular periférica em pessoas acometidas com DM (BRASIL, 2016).

Pacientes portadores de UPD tem maior probabilidade de sofrerem amputações não traumáticas de membros inferiores devido à probabilidade de terem cicatrização mais lenta e/ou ineficaz em relação a outros indivíduos não portadores de UPD. Isto se dá em virtude da circulação local prejudicada (FERREIRA, 2020). Outra característica é a alteração do tecido muscular e da anatomia óssea dos pés provocada pelo surgimento de pontos de pressão e ressecamento cutâneo que afeta a elasticidade protetora da pele (SIQUEIRA *et al.*, 2019).

O surgimento está associado a múltiplos fatores, tais como Doença Arterial Periférica, (DAP), alterações biomecânicas provocadas pela destruição osteoarticular e deformidades decorrentes da neuro Artropatia (dedos em garra, dedos em martelo, proeminências em ante pé) ou outros que podem alterar as pressões de apoio na planta do pé (FERREIRA, 2020). Quanto mais presentes os sintomas citados, maiores são os riscos do indivíduo em desenvolver UPD e necessitar de amputação de membros (BRASIL, 2016).

Cabe ressaltar que a DAP é caracterizada pelo estreitamento das artérias e diminuição do fluxo sanguíneo. Quando associada a pequenas lesões, causam dor e agravamento no quadro clínico. Contudo, se relacionada a neuropatia (pés neuropáticos) pequenos ferimentos podem ocorrer de forma assintomática. Para o portador de UPD a DAP representa um risco maior de infecção e agravamento da sua condição devido à presença de hiperglicemia, a fatores relacionados à imunidade celular e ao ressecamento da pele (SIQUEIRA *et al.*, 2019).

Em relação a classificação das UPD, considera-se os aspectos fisiopatológicos apresentados em cada caso. Assim, o pé diabético é categorizado como neuropático, isquêmico (também chamado de vascular) e misto (neurovascular ou neuroisquêmico) (BRASIL, 2016).

Em síntese, o pé neuropático é caracterizado pela perda progressiva da sensibilidade, que faz com que o acometido não perceba pequenos traumas na região afetada que podem evoluir para um quadro ulcerativo mais grave. Por outro lado, o pé isquêmico é caracterizado por claudicação intermitente (dor parecida com câibra, que se apresenta ao caminhar e alivia com o repouso, causada pela chegada de sangue insuficiente aos músculos das pernas) e/ou dor na elevação do membro (BRASIL, 2016). Na Tabela 1 são apresentados os sinais e sintomas dos tipos de lesões, conforme descrito neste parágrafo.

Tabela 1. Sinais e sintomas dos tipos de Pé Neuropático e Pé Isquêmico.

Sinais e sintomas	Pé Neuropático	Pé Isquêmico
Temperatura do pé	Quente ou morno.	Frio.
Coloração do pé.	Coloração normal.	Pálido com elevação ou cianótico com declive
Aspecto da pele do pé	Pele seca e fissurada	Pele fina e brilhante.
Deformidade do pé.	Dedo em garra, dedo martelo, pé de Charcot ou outro.	Deformidade ausentes.
Sensibilidade.	Diminuída, abolida ou alterada (parestesia).	Sensação dolorosa, aliviada quando as pernas estão pendentes
Pulso pediais.	Pulsos amplos e simétricos	Pulsos diminuídos ou ausentes
Calosidade.	Presentes, especialmente nas plantas dos pés.	Ausente.
Edema.	Presente.	Ausente.
Localização mais comum da úlcera (se houver).	1º e 5º metacarpos e calcâneos (posterior), redondas, com anel querostático periucérático; não dolorosa.	Letro-digital, sem anel querostático dolorosa.

Fonte: (BRASIL, 2016)

2.2 Sistema terapêutico para neoformação tecidual - RAPHA®

Dado o cenário epidemiológico do pé diabético, a UnB desenvolveu um sistema terapêutico para UPD, denominado sistema de neoformação tecidual - RAPHA®, que consiste em uma estratégia que associa a fototerapia, por meio de um equipamento portátil, com Biomembranas de Látex Natural - BLN (GUIMARÃES, 2019).

A concepção do sistema RAPHA® foi baseada nos estudos prévios demonstrando o potencial terapêutico da utilização da BLN (proveniente da seringueira *Hevea brasiliense*) e da fototerapia com LED no comprimento de onda de luz vermelha (ROSA *et al.*, 2020, 2019).

Foi demonstrado que o uso da BLN induziu neoformação tecidual e estimulou o processo de cicatrização, bem como aumento do número de fibroblastos (ROSA *et al.*, 2019). Já as pesquisas que utilizaram a fototerapia perceberam o aumento da proliferação de fibroblastos, síntese de colágeno, neovascularização do tecido isquêmico e o aumento da atividade bactericida, além da redução do processo inflamatório (KUSHIBIKI *et al.*, 2015).

Foi estabelecida um acordo de cooperação entre UnB e Ministério da Saúde (MS) em 2017 a fim de realizar ensaios clínicos para investigar a eficácia e segurança do sistema para uso estratégico no Sistema Único de Saúde (SUS). O ensaio clínico foi coordenado pela professora Dra. Suélia de Siqueira Rodrigues Fleury Rosa que foi a inventora principal da terapia (patente” BR 102016019963-8 A2). O sistema terapêutico RAPHA® foi submetido a avaliações em ensaios clínicos de fase 1, 2 e 3 entre 2017 e 2019 (GUIMARÃES, 2019).

Para realização do ensaio clínico foi disponibilizado a cada participante um kit contendo o equipamento RAPHA® e biomembranas de BLN, a solução salina (soro fisiológico), tesoura, gaze, esparadrapo e manual de instruções – Figura 1 (ROSA *et al.*, 2020).

A inserção desta tecnologia no SUS poderia implicar na redução de gastos com tratamentos convencionais e desafogamento dos atendimentos prestados nos ambulatórios (ROSA *et al.*, 2020). Para o paciente, os benefícios incluem melhor qualidade de vida por se tratar de um tratamento domiciliar, evitando, assim, deslocamento constante ao hospital (SANTANA, 2021).

A partir de 2019, a nossa equipe desenvolveu biomembranas com nanotecnologia e biocompostos e um termo aditivo de pedido de patente de invenção foi depositado no Instituto Nacional de Propriedade Intelectual (INPI) em 02/02/2021 sob o registro - BR 1320210019440. O pedido de patente intitulado "Biomembranas a base de látex" (*Hevea brasiliensis*) contendo lipossoma com curcumina (*Curcuma Longa*) e Papaína (*Carica papaya*). Seu uso está associado a LED terapia para tratamento de úlceras crônicas e feridas diabéticas. Trata-se do desenvolvimento de um curativo dérmico baseado em látex natural contendo lipossomas com curcumina e papaína, os quais são biocompostos com ação anti-inflamatória e debridante (BRASIL, 2016; ROSA *et al.*, 2019).

A curcumina é um biocompostos encontrado no açafrão, o qual é popularmente conhecido como uma especiaria. É caracterizado como uma erva originária da Índia, composta de um rizoma principal com ramificações menores, todas marcadas com anéis de brácteas secas. Embora seja popularmente conhecida como condimento, é muito cultivado como planta medicinal. Seu uso medicinal tem sido atribuído às suas propriedades antiparasitária, antiespasmódica, antibacteriana e anti-inflamatória (DA SILVA FILHO *et al.*, 2009).

Conforme defendeu Thamis Fernandes Santana (2021), quando comparado ao tratamento convencional oferecido pelo SUS, o uso de biomembranas de látex associado a curcumina se demonstrou eficaz, devido a velocidade na resposta do organismo ao tratamento. Isto pois as biomembranas com curcumina estimula a produção do tecido de granulação, redução de tecidos não viáveis e na contração e redução das bordas da ferida. Além disso, em contato com a ferida, a biomembrana absorveu o exsudato e promoveu a umidade necessária à cicatrização (SANTANA, 2021)



Figura 1. Sistema terapêutico para neof ormação tecidual RAPHHA®. (a) O kit fornecido a cada participante do estudo; (b) Dispositivo RAPHHA®; (c) Exemplo de uso do dispositivo. Fonte: Autor.

2.3 Avaliação de feridas

A avaliação de feridas é tão relevante quanto o próprio cuidado, pois permite reconhecer o estado da ferida e, assim, traçar as melhores estratégias para o cuidado com a lesão. Assim, para uma avaliação adequada, o profissional deve realizar a anamnese pontuando fatores de risco e possíveis complicações, exame físico de úlceras, deformidades e outras alterações, avaliação neurológica por meio de teste de sensibilidade tátil ou de sensibilidade vibratória e vascular (palpação de pulsos pediosos e tibiais posteriores) (BRASIL, 2016). Além destes, uma avaliação assertiva deve considerar complicações micro e macrovasculares (complicações relacionadas a DM), sinais de neuropatia e nefropatia diabética e tabagismo (LUCOVEIS *et al.*, 2018).

Atualmente, a forma mais comum de avaliação de feridas crônicas consiste na identificação visual do tecido danificado por meio de determinação de cores dominantes, como vermelho-amarelo-preto e medições de área, perímetro e profundidade para comparações futuras a fim de se verificar a redução das dimensões e progresso de cicatrização (CUNHA; DUTRA; SALOMÉ, 2018). As medições da ferida são obtidas através de medição com régua milimétrica (Figura 2) ou com o contato direto da lesão com papel vegetal transparente que depois é colocado em

uma grade métrica (no entanto, o contato com papel vegetal eleva o risco de infecção) e ainda através de fundições de alginato e injeção de soro (NOURI *et al.*, 2013).



Figura 2. Método de medição tradicional da ferida. (a) Aferição da altura das feridas. (b) Medição da extensão da úlcera. Fonte: Banco de dados do projeto RAPHA®.

A análise Imuno-Histoquímica (IHQ) demonstra-se uma alternativa eficaz para aferição do estado de cicatrização da ferida. Trata-se de uma abordagem que combina técnicas histológicas, imunológicas e bioquímicas com o intuito de identificar e avaliar antígenos (fragmentos tissulares ou celulares), através de reações com anticorpos específicos, por meio de cortes histológicos, esfregaço ou suspensão celular. Tais procedimentos permitem ao profissional de saúde realizar uma avaliação visual da distribuição e localização de componentes celulares específicos, tanto na célula quanto no tecido, de forma a permitir a identificação de fibroplasia, angiogênese e reepitelização a partir de marcadores (anticorpos) (WERNER *et al.*, 2005).

2.4 Classificação das feridas conforme a Universidade do Texas

Uma vez avaliada, a ferida é classificada para que se tenha o entendimento sobre as condições num dado momento devido as características inerentes a cada classe. Assim, a classificação fornece uma base para a comparação da evolução da ferida tendo como finalidade definir o risco de complicações. Atualmente, os sistemas de classificação validados pelos órgãos de saúde internacionais incluem: *Meggitt-Wagner; Site; Ischaemia, Neuropathy; Bacterial infection, Area and Depth* (SINBAD);

Wound, Ischemia, Foot Infection (WIFI) e Universidade do Texas (SCHAPER *et al.*, 2019).

A classificação de Meggitt-*Wagner* é simples, mas não contempla a perda da sensibilidade protetora, infecção e isquemia (BRASIL, 2016). Já a SINBAD é um sistema de pontuação projetado para fornecer informações de prognóstico (SCHAPER *et al.*, 2019) e o WIFI se baseia em três fatores de risco de amputação: ferida (*Wound*), isquemia (*Ischemia*) e infecção (*Foot Infection*) (CERQUEIRA *et al.*, 2020).

Dentre estas, o Ministério da Saúde orienta os profissionais em seu manual do pé diabético, a adotarem a classificação de Ferida Diabética da Universidade do Texas - *University of Texas Diabetic Wound Classification System* (BRASIL, 2016). Tal sistema classifica UPD por meio de uma matriz bidimensional 4 × 4, tabela 2, categorizando características como profundidade (Grau 0, 1, 2, 3) e presença de infecção (Estágio B), isquemia (Estágio C) ou ambos (Estágio D) (WERNER *et al.*, 2005).

Assim, tal classificação, por organizar as informações da ferida em uma matriz, torna o processo de avaliação e entendimento do estado de ulceração mais intuitivo, visto que basta cruzar as referências (linha × coluna) para se ter uma noção do estado ulcerativo da ferida. Quanto mais próximo ao A-0 melhor o estado de cicatrização. Por outro lado, quanto maior a distância de A-0, maior a necessidade de cuidado (CERQUEIRA *et al.*, 2020).

Tabela 2. Classificação de Ferida Diabética da Universidade do Texas.

Estágio	Grau			
	0	I	II	III
A	A Lesão pré ou pós-ulcerativa completamente eptelizada	Ferida superficial não envolvendo tendão, cápsula ou osso	Ferida com exposição de tendão ou cápsula	Ferida com exposição de osso ou articulação
B	Infecção	Infecção	Infecção	Infecção
C	Isquemia	Isquemia	Isquemia	Isquemia
D	Infecção e Isquemia	Infecção e Isquemia	Infecção e Isquemia	Infecção e Isquemia

Fonte: (CERQUEIRA *et al.*, 2020).

Tal como citado, o Ministério da Saúde (MS) adota esta classificação para organização de registros dos usuários do serviço público. Da mesma forma, o projeto RAPHA® adotou este modelo para a documentação dos resultados de forma a alinhar os registros com a padronização oficial, o que permite realizar análises posteriores dos resultados obtidos (GUIMARÃES, 2019).

2.5 Inteligência Artificial

A Inteligência Artificial (IA) refere-se tanto a uma tecnologia quanto a um campo de estudo acadêmico. Pode assim, ser entendida como um sistema de software criado com a intenção de simular a inteligência humana a partir de dados externos. Assim, ao interpretar estes, com a IA é possível determinar os possíveis caminhos para classificação e treinamento de aprendizado. Através de um processo similar ao de tentativa e erro, dentre as possibilidades aferidas, por meio da IA é possível predizer qual melhor classificação (KAPLAN; HAENLEIN, 2019).

Criada em meados da década de 1950, a IA visava trabalhar com problemas de maior complexidade matemática, em processos com incerteza ou mesmo estocásticos por natureza como eventos aleatórios tais como o de lançar de dados, onde qualquer uma das 6 faces tem iguais probabilidades de ficar para cima) (SIDDIQUE; ADELI, 2013).

Assim, desde a sua gênese, a IA desenvolveu-se com o intuito de fazer com que os computadores se comportassem de forma inteligente, semelhante ao cérebro humano. A partir da indagação de Alan Turing, considerado pai da computação, “Podem as máquinas pensar?” e a partir dessa premissa, propôs-se um teste para saber se os computadores eram capazes de aprender. Resumidamente o teste de Turing consiste em um humano conseguir distinguir se ele está conversando com outro humano ou com uma máquina. Assim, caso o humano não fosse capaz de conseguir distinguir se o interlocutor é uma máquina, o sistema poderia ser considerado inteligente (TURING, 2009). Hoje muitos sistemas de IA passam no teste de Turing, mas a capacidade de aprender dos computadores ainda não é igual à capacidade de aprender dos humanos (PRIMO *et al.*, 2000).

Desse modo, a IA enquanto objeto de estudo se relaciona com outras áreas do conhecimento como biologia, matemática, linguística, engenharia, filosofia, dentre outras. Como consequência, sua aplicação também se relaciona com diversos ramos, desde aplicações científicas mais complexas ao entretenimento. De tal forma, é possível encontrar IA voltada para a robótica, Processamento de Linguagem Natural ou mesmo em Sistemas Especialistas, sistemas projetados para processamento das informações não numéricas, capaz de apresentar conclusões desde que devidamente orientado e alimentado (GOMES, 2010).

O aumento da capacidade computacional e aparecimento de novos seguimentos de mercado impulsionaram o desenvolvimento de novas técnicas de aprendizado. Atualmente, o desenvolvimento combina várias abordagens, como por exemplo, a lógica Fuzzy e as redes neurais artificiais. Em linhas breves, a lógica Fuzzy, também conhecida como teoria de possibilidades, é um método que permite traduzir em termos matemáticos expressões vagas, expressa por um conjunto de regras linguística. Assim, esse método permite que uma variável seja parcialmente verdadeira ou parcialmente falsa (diferente do método tradicional onde uma

proposição é obrigatoriamente verdadeira ou falsa), o que possibilita maior gama de estratégias de tomadas de decisão em problemas complexos (REGES *et al.*, 2017; SIMÕES; SHAW, 2007).

A teoria Fuzzy pode ser agregada aos sistemas de redes neurais, que em síntese, é uma estrutura projetada para simular o funcionamento do sistema nervoso, através de um algoritmo de aprendizagem cuja função é modificar os pesos “sinápticos” da rede de forma ordenada. Uma vez realizado o processo de aprendizagem, os dados são armazenados como conhecimento experimental e disponibilizado para uso (HAYKIN, 2007).

Em relação à tipologia, a IA pode ser classificada em três tipos: Focada, Generalizada e Superinteligente. A primeira, IA Focada (também conhecida como IA Fraca) consiste em algoritmos especializados em resolver problemas de uma área específica. Estes geram uma grande quantidade de dados e os algoritmos são capazes de realizar tarefas complexas, sempre direcionadas a um objetivo específico. A segunda, IA Generalizada ou Forte, destina-se a desenvolver sistemas com desempenho semelhante aos seres humanos. Nesta categoria, encontra-se a técnicas de AM. Por fim, a IA Superinteligente refere-se a sistemas mais capazes que humanos em praticamente todas as tarefas. De forma prática, está mais como ideal do que um sistema real (LUDERMIR, 2021).

No Aprendizado Não-Supervisionado, algoritmo é alimentado com exemplos não rotulados a fim de que sejam examinados os exemplos pelas similaridades dos seus atributos e também sejam ordenados, gerando agrupamentos ou clusters. Uma vez feito isso, é necessária uma análise para determinar o que cada agrupamento significa no contexto do objetivo esperado (LUDERMIR, 2021).

2.5.1 Aprendizado de máquina

Conforme citado, o AM é uma área da Inteligência Artificial considerada generalizada, destinada a criar algoritmos capazes de melhorar seu desempenho por meio de exemplos. Seu desenvolvimento utiliza técnicas de aprendizado baseado nas informações fornecidas, assim, aprendem automaticamente a partir de grande quantidade de dados. Sob essa lógica, a inferência indutiva (conclusão ou hipótese

gerada após avaliação de um número de casos particulares) é um dos principais métodos utilizados para gerar conhecimento novo e prever eventos futuros em AM. Como consequência, quanto mais preciso forem os dados, mais precisas serão as generalizações resultantes (LUDERMIR, 2021).

Conforme explica Aurélien Géron (2019), O AM é classificado em três principais tipos: supervisionado, não supervisionado e aprendizado por reforço (GÉRON, 2019).

No primeiro tipo, para cada exemplo apresentado ao algoritmo de aprendizado é necessário apresentar a resposta desejada, ou seja, um rótulo informando a que classe o exemplo pertence (como no caso deste estudo) (GÉRON, 2019). Cada exemplo é descrito por um vetor de valores (atributos) e pelo rótulo da classe à qual deve estar associada. O objetivo é construir um classificador que possa determinar corretamente a classe de novas amostras ainda não rotuladas. Esse método de aprendizado é o mais utilizado (LUDERMIR, 2021).

Como variação da abordagem, o aprendizado não supervisionado funciona como o supervisionado. Contudo, utiliza um segundo conjunto de treinamento composto por exemplos não rotulados. O objetivo é treinar o classificador quando um número de exemplos não rotulados está disponível juntamente com os rotulados, de forma a avaliar a acurácia do sistema (GÉRON, 2019).

No Aprendizado Não Supervisionado, o algoritmo é alimentado com exemplos não rotulados a fim de que o algoritmo, examine os exemplos pelas similaridades dos seus atributos e os ordene, gerando agrupamentos ou clusters. Uma vez feito isso, é necessária uma análise posterior para determinar o que cada agrupamento significa para o sistema (GÉRON, 2019).

Por fim, no Aprendizado por Reforço, o algoritmo não recebe a resposta correta, mas um sinal de reforço (recompensa ou punição). Assim, o próprio algoritmo gera uma hipótese baseado no reforço e determina se essa hipótese foi boa ou ruim. Este tipo de AM é bastante utilizado em robótica e jogos (LUDERMIR, 2021).

2.5.2 Redes neurais artificiais

Redes neurais são inspiradas pelos avanços na determinação experimental das propriedades eletrofisiológicas do neurônio e pelos recentes resultados de Alan

Turing e John Von Neumann que defendiam ser booleana a natureza essencial da inteligência. Ou seja, a inteligência seria resultante da atividade neural. Em 1943, Warren McCulloch em conjunto com Walter Pitts publicaram um artigo intitulado “*A logical calculus of the ideas immanent in nervous activity. Bulletin of Mathematical Biophysics*”, considerado ainda hoje referência para a teoria de Redes Neurais Artificiais (RNA) (KOVÁCS, 2002).

Segundo os autores, a relação entre inteligência e atividade nervosa pode ser estabelecida de forma científica, uma vez que, com as devidas simplificações, o sistema nervoso (composto por redes de neurônios) pode ser implementado com funções booleanas (MCCULLOCH; PITTS, 1943).

Assim, surgem os modelos matemáticos inspirados nas estruturas neurais biológicas e que tem a capacidade computacional adquirida por meio de aprendizado. O processamento da informação em Redes Neurais Artificiais (RNA) é feito nos neurônios artificiais, posteriormente conhecidos como Neurônio McCulloch e Pitts (MCP) (ou somente modelo MCP) (LUDERMIR, 2021).

Conforme explica o professor Zsolt L. Kovács (2002), o modelo MCP Foi um trabalho pioneiro, contudo rudimentar, as teorias posteriores se propuseram a melhorar o modelo. De tal modo, em 1957, o psicólogo Frank Rosenblatt, considerado um dos pais da Aprendizagem Profunda, propõe um conceito mais simples de Aprendizado com Redes Neurais, denominado Perceptron (ROSENBLATT, 1957).

Neste método, a rede pode ser composta a partir de uma única camada, tendo como base os neurônios MCP e uma regra de aprendizado de correção de erros (diferença entre a resposta real e a desejada). O aprendizado é realizado em duas fases: treinamento e teste. Na primeira, os exemplos rotulados são apresentados ao algoritmo. Os parâmetros, ou pesos, são ajustados a cada novo exemplo. A segunda fase é responsável pela avaliação do sistema (ROSENBLATT, 1957)

As redes Perceptron começaram a apresentar melhores resultados que anteriores, várias camadas (ou redes) foram sendo empregadas nos mais diversos trabalhos, como reconhecimento de imagens, até a popularização das Neurais com múltiplas camadas: as Redes Neurais Profundas (do inglês, *Deep Neural Networks*) (LUDERMIR, 2021).

3. MATERIAL E MÉTODOS

O desenvolvimento do programa classificador de úlceras, neste estudo (foi estruturado em etapas, iniciando na escolha da linguagem de programação e finalizando-se nos testes realizados por profissionais de saúde para validação dos resultados apresentados pelo sistema, conforme ilustrado na figura 3.

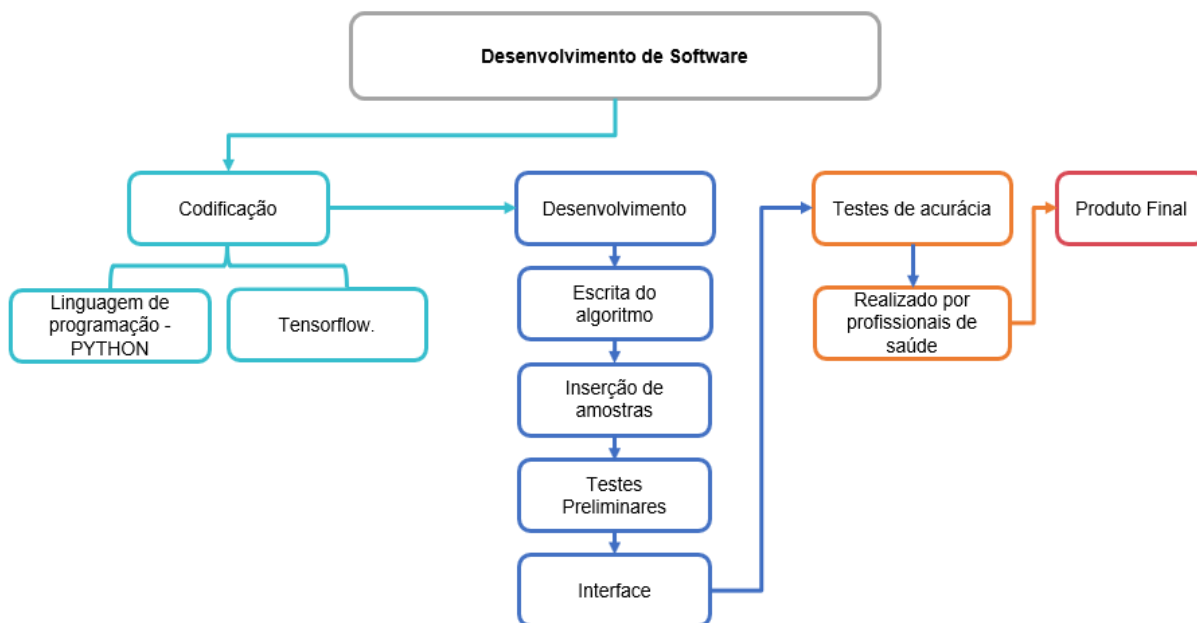


Figura 3. Organograma da metodologia adotada por este estudo. A concepção do estudo adotou duas fases complementares: codificação (escolha da linguagem de programação), desenvolvimento do sistema e teste de acurácia. O produto final consiste no programa classificador de úlceras.

3.1 Estudo clínico: caracterização da amostra

As amostras para análise de dados foram obtidas de fotografias obtidas em ensaio clínico controlado, cujo protocolo foi previamente aprovado pelos Comitês de Ética em Pesquisa em Seres Humanos da Faculdade de Saúde (Universidade de Brasília) e Conselho Nacional de Ética em Pesquisa (Conep) sob o Certificado de Apresentação para Apreciação Ética (CAEE) de número 94910718.5.0000.0030.

O protocolo foi aplicado nas dependências do Ambulatório do Pé Diabético do Hospital Regional da Asa Norte (HRAN-DF), no Hospital Regional do Gama (HRG) e

nas residências dos participantes de pesquisa. Todos os participantes assinaram o termo de consentimento livre e esclarecido antes da participação na pesquisa.

A população foi composta por indivíduos portadores de úlceras diabéticas de membros inferiores com indicação de tratamento ambulatorial. Neste estudo, os participantes de pesquisa foram alocados em três grupos experimentais:

1. Grupo Controle (GC): composto por participantes que utilizaram o protocolo adotado no SUS para o tratamento de úlceras diabéticas.
2. Grupo Experimental 1 (GE1): participantes que utilizaram o protocolo experimental empregando biomembrana de látex natural em associação com irradiação por LED no comprimento de onda vermelho (entre 635 e 640 nm) (Rapha®).
3. Grupo Experimental 2 (GE2): participantes que utilizaram o protocolo experimental empregando biomembrana de látex natural contendo lipossomas de curcumina em associação com irradiação por LED no comprimento de onda vermelho (entre 635 e 640 nm) (Rapha® *plus*).

Os participantes do grupo controle (GC) receberam os curativos e tratamento do protocolo adotado pelo SUS e foi realizado pela equipe de saúde especializada do Ambulatório do Pé Diabético, ao menos uma vez na semana. A realização do protocolo do grupo controle era escolhida de acordo com avaliação do enfermeiro do ambulatório. Os curativos mais comumente utilizados nestes pacientes foram alginato de cálcio, hidrogel e carvão ativado com prata.(FERREIRA, 2020)

Os participantes dos grupos experimentais (GE1 e GE2) eram pacientes do Ambulatório do Pé Diabético. Sendo assim, todos eles utilizaram, anteriormente, o tratamento aplicado no SUS antes de iniciar os protocolos experimentais. Os participantes dos grupos GE1 e GE2 realizaram tratamento em domicílio com uso da biomembrana e do equipamento à base de LED (dispositivo Rapha®).

Os protocolos de ambos os grupos experimentais foram realizados de forma autônoma ou com auxílio de familiar, nos quais a troca do curativo era feita diariamente. Adicionalmente, os participantes dos grupos experimentais também receberam visitas domiciliares de membros do projeto de pesquisa, uma vez por

semana, figura 4. A visita da equipe do projeto não alterou a agenda dos participantes no ambulatório os quais estavam alocados.

Além das visitas, realizava-se o acompanhamento diário dos participantes por meio de comunicação no aplicativo WhatsApp, de forma a documentar o máximo possível as intercorrências e resultados do tratamento. Neste contexto, foram realizados os registros fotográficos que serviram de base para o desenvolvimento deste estudo.

No grupo GE2 o uso da BLN com curcumina era intercalado com o uso de BLN sem curcumina. A equipe multidisciplinar era constituída por pesquisadores enfermeiros, biomédicos e pesquisadores com diversas especialidades. O ensaio clínico ocorreu entre 2018 e 2019.

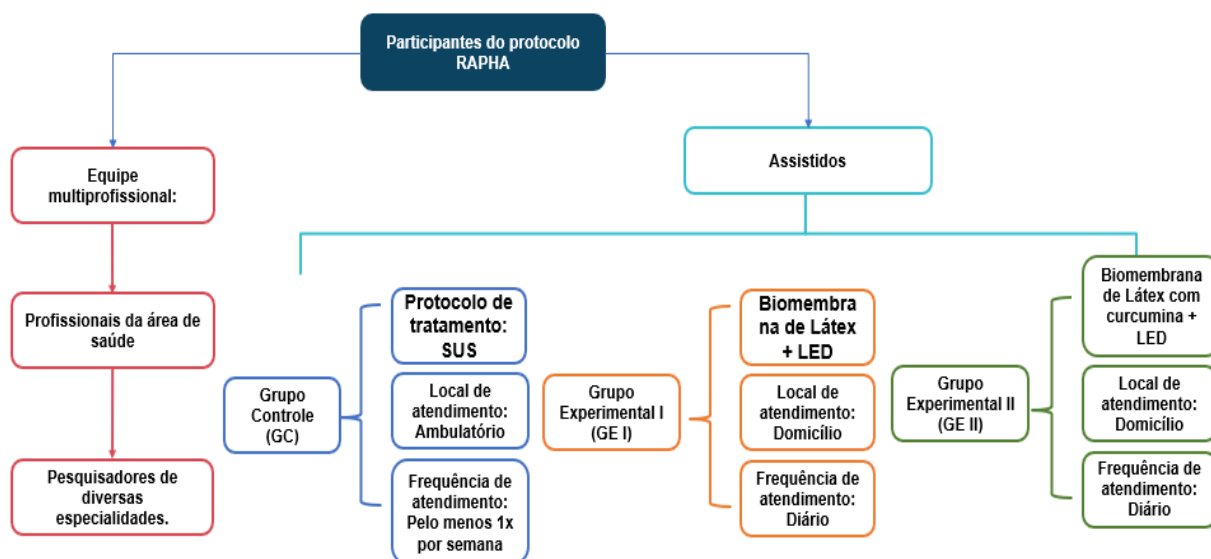


Figura 4. Organização da execução do ensaio clínico. A equipe de pesquisadores foi composta por profissionais de diversas especialidades. Os participantes de pesquisa foram alocados em três grupos experimentais: GC, GEI e GEII que receberam diferentes intervenções terapêuticas. Fonte: SANTANA, 2021.

A cada visita domiciliar, feita pelos pesquisadores do estudo, foi feito o registro de dados sobre o estado clínico dos participantes tais como medidas de pressão arterial, temperatura, medidas das bordas e profundidade e registro fotográfico da ferida, de forma a acompanhar a evolução da cicatrização e saúde geral dos participantes de pesquisa. Foram usadas 554 imagens obtidas pelos registros fotográficos como amostra deste estudo. Todas as imagens foram analisadas e em

seguida agrupadas conforme a classificação da Universidade do Texas (estágio A-0 ao D3). Estas amostras foram utilizadas para análise na fase de aprendizado de máquina, não sofrendo alterações por edição de imagem ou identificação, conforme apresentado na figura 5.

3.2 Desenvolvimento do algoritmo de classificação de imagens

O conceito universal de algoritmo para a computação pode ser dado como um conjunto das regras e procedimentos lógicos que levam à solução de um problema em um número finito de etapas. Em termos simples, é um conjunto de instruções (passo a passo) definidas em formas de códigos que um programa deve seguir para que funcione. Um algoritmo eficiente deve seguir instruções claras e bem definidas dentro de uma lógica pré-determinada. Com efeito, o funcionamento de qualquer sistema computacional depende da execução correta do algoritmo (MENÉNDEZ, 2021).

A escrita do algoritmo, ou código fonte, adotou a metodologia de Aprendizado de Máquina, por ser uma solução computacional gera modelos analíticos robustos, capazes de analisar uma grande quantidade de dados e entregar resultados confiáveis. Além disso, há uma vasta bibliografia para desenvolvimento utilizando a técnica, uma vez que é utilizada em trabalhos científicos. Nesse sentido, a programação deste estudo utilizou como bibliografia principal a documentação oficial da linguagem de programação e do módulo de desenvolvimento Tensorflow².

De forma mais detalhada, o método de AM permite identificar padrões (também definido como aprendizado) partir de um conjunto de exemplos (amostras) para tomar decisões com o mínimo de intervenção humana. O treinamento (ciclo de processamento no qual o modelo aprende a tomar decisões baseado nas amostras) utilizou as amostras (registros fotográficos do RAPHA) organizados em pastas conforme a classificação da ferida, figura 06, a fim de que estabelecer correlações com a classificação dada pelo programa. O estabelecimento de correlações entre a classificação manual (realizada pela análise do profissional de saúde) e automática

² Documentação oficial está disponibilizada em <<https://www.tensorflow.org/>>.

(classificação do programa) foi definido e avaliada a acurácia de classificação feita das duas maneiras.

Para escrita do algoritmo foi adotada a Linguagem programação Python (versão 3.9), pois esta disponibiliza suporte à programação com Inteligência Artificial, seja por meio de módulos de desenvolvimento, como o Tensorflow, ou mesmo por API (*Application Programming Interface* ou interface de programação de aplicações, em português), sendo todos de código aberto.

O módulo de desenvolvimento de sistema Tensorflow, consiste em uma biblioteca de código aberto aplicável dedicado a criação e treinamento de redes neurais para detectar e decifrar padrões e correlações (CORTEZ, 2022).

API, consiste em de códigos prontos, voltados a determinadas funções, como criar e gerenciar o número de camadas e neurônios da rede e otimizar a execução do programa, não exigindo que o programador reescreva estas funções, poupando tempo e tornando o desenvolvimento mais simples (MACIEL, 2022).

O conjunto amostral foi composto por aproximadamente 554 registros fotográficos coletados durante o ensaio clínico do projeto RAPHA® realizado entre 2018 e 2019. As feridas dos participantes de pesquisa foram fotografadas no início (dia 0), meio (21° dia) e término (no 42° dia) do protocolo de forma a documentar a progressão da cicatrização, conforme exemplificado na figura 5.



Figura 5. Exemplo de amostras utilizadas. Registro fotográfico da evolução da úlcera no dia 0 (a) 21° dia (B) e 42° dia (C). Fonte: Banco de dados do protocolo RAPHA®.

Os registros fotográficos foram classificados e organizados em pastas pela profissional de saúde Luciene Ferreira dos Anjos. Esta organização foi feita para agrupar as características das amostras e facilitar o uso de dados para análise por IA a fim de comparar a classificação feita de maneira manual e automática e avaliar a coincidência de classificação (Figura 6).



Figura 6. Organização das imagens em pastas seguindo a classificação da Universidade do Texas. Fonte: Banco de dados do protocolo RAPHA.

Uma vez feita a classificação pelo programa era feita a "importação de dados", Figura 7. Esta técnica possibilitava a avaliação da classificação por IA em que consistia em análise das características das amostras para fins de comparação por classificação. Ressalta-se que as imagens não sofreram quaisquer alterações. Uma vez importados, o algoritmo utilizou 80% dos registros para o treinamento do programa e o restante (20%) foi utilizado na fase de validação de dados.

```

24 # Seleciona o diretório com as imagens a serem processadas.
25 dataset_url = os.path.abspath("./fotos")
26 data_dir = pathlib.Path(dataset_url)
27 image_count = len(list(data_dir.glob('*/*.jpg')))
28
29 print("Processando %d imagens do diretório de treinamento %s..." % (
    image_count, data_dir))

```

Figura 7. Linhas de código responsável pela importação das imagens para o algoritmo iniciar o treinamento. Fonte: Autor

3.3 Desenvolvimento do algoritmo de classificação

O Aprendizado de Máquina é realizado em ciclos de processamento, onde inicia-se com a inserção de dados amostrais (conjunto de dados para treinamento) e finaliza-se com a saída de dados (resposta), conforme ilustrado na figura 8.

Cada ciclo é dividido em fases, iniciando-se pelo pré-processamento (preparativos para o treinamento) em que o algoritmo carrega as amostras a serem treinadas. Uma vez iniciado, a fase posterior (aprendizado) é dedicada aos treinamentos (ou aprendizados) a partir dos dados da fase anterior.

Na fase seguinte, denominada prognóstico, é gerado um modelo de IA treinando-se e iniciando-se os testes de performance e validação de resultados. Os resultados dos testes irão subsidiar novos ciclos de aprendizado para aumento da acurácia e ajuste de desempenho. Por fim, a última fase apresenta os resultados obtidos (respostas) ao mesmo tempo em que aceita novas amostras para classificação, conforme o modelo gerado.

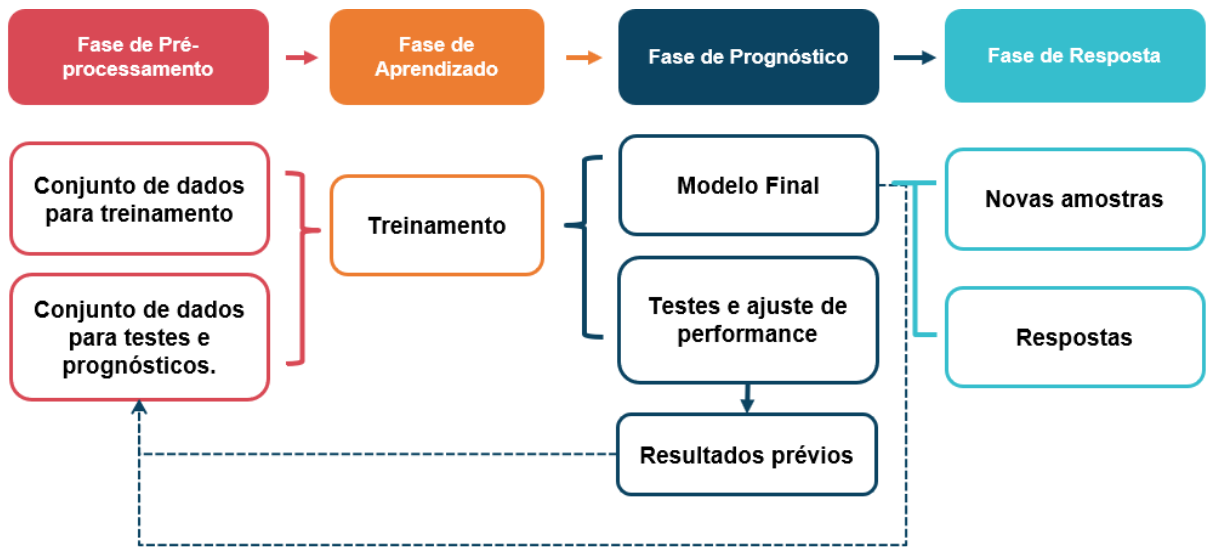


Figura 8. Modelo esquemático do funcionamento do Aprendizado de Máquina, dividindo o em fases de processamento (com adaptações). Fonte: (RASCHKA; MIRJALILI, 2017).

A lógica aplicada ao algoritmo determina o funcionamento do programa, sendo que contém as etapas a serem seguidas para que se obtenha o resultado desejado. Assim, considerando o modelo proposto aqui, a escrita do algoritmo foi elaborada seguindo as seguintes etapas:

1. Inserção de dados: o usuário insere novas amostras para serem classificadas;
2. Análise das amostras para identificação de padrões de ferida (bordas, coloração etc.) por meio do aprendizado realizado na fase de desenvolvimento, a fim de determinar se a nova amostra deve ser rejeitada ou processada.
3. Tomada de decisão: Caso a amostra não contenha padrões, deve ser rejeitada, sendo o processo encerrado. Se contiver, será analisada pela IA a fim de ser classificada.
4. O processo de classificação será encerrado, apresentando ao usuário uma mensagem de erro, por exemplo: a imagem não contém padrões de ferida.
5. O modelo de IA realizar nova fase de aprendizado, prognóstico e resposta;
6. Uma vez classificadas, o processo se encerrava apresentado os resultados obtidos. Este funcionamento está ilustrado na figura 9.

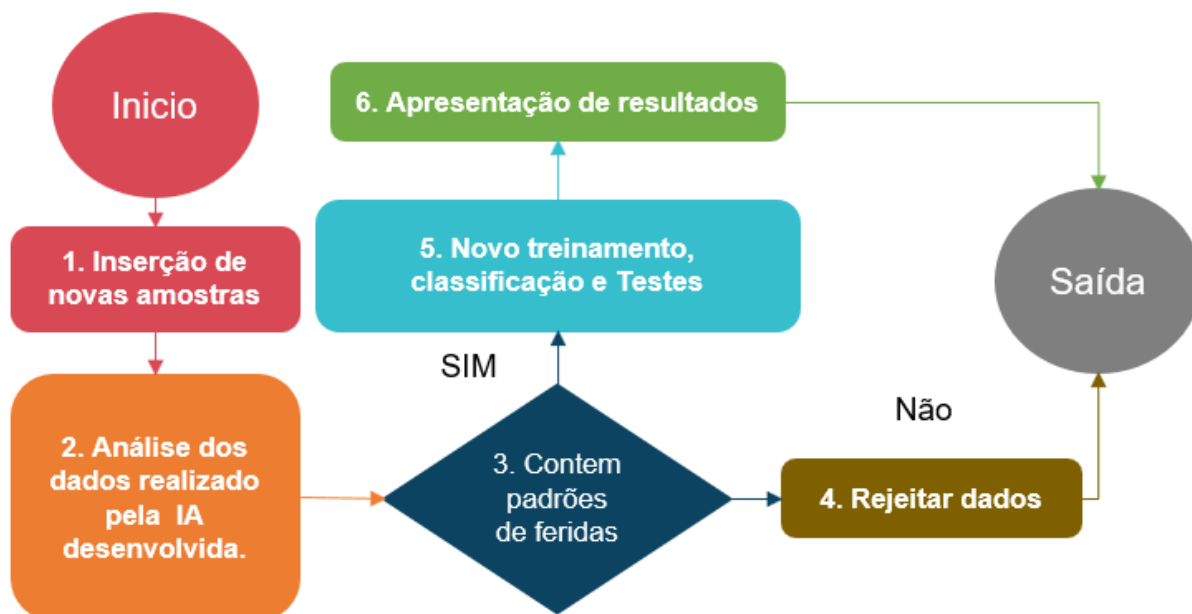


Figura 9. Lógica para o comportamento do classificador. Fonte: autor

3.3.1 Execução do algoritmo

Após estas etapas de desenvolvimento, iniciou-se os testes de execução do algoritmo, o qual foi realizado da seguinte maneira:

1. Carregamento das amostras, considerando que cada subpasta está nomeada com a devida classificação.
2. Criação de um grupo de treinamento com o lote contendo 32 imagens, com o redimensionamento máximo das imagens de 360×360 pixels e percentual de validação de 20% e com 30 ciclos de execução.
3. Normalização dos dados das imagens, ou seja, redução de dados e do volume de dados com resultados similares;
4. Treinamento efetivo do modelo.
5. Verificação dos dados do treinamento.
6. Execução *Dropout*. Técnica que atua de reduzindo aleatoriamente uma percentagem de neurônios nas camadas da rede neural, isso diminui o

overfitting (problema relacionado as fases de treinamento e teste, onde ao receber dados novos, o modelo de aprendizado não consegue aplicar as regras corretamente e tem o desempenho afetado).

7. Compilação do modelo com o grupo de validação de dados.
8. Verificação do resultado do modelo após o aumento de dados.

A Compilação do aprendizado de máquina foi realizada usando os parâmetros: otimizador, cálculo de perda e métrica de cálculo. Todos estes são definidos de forma automática, segundo a documentação oficial da linguagem de programação (tensorflow.org).

Em relação ao otimizador utilizou-se o método Adam, que é um método gradiente descendente estocástico baseado em uma estimativa adaptativa de primeira e segunda ordem. Este método foi escolhido porque ele é computacionalmente eficiente, possui pouca necessidade de memória, é invariante de reescala dos gradientes e é bem adaptado para os problemas em termos de larga escala de dados e parâmetros (KINGMA; BA, 2015).

Para realização do cálculo de perda usou-se o *Sparse Categorical Crossentropy* visto que é o tipo indicado pelo *TensorFlow* para quando se tem mais de duas categorias de classificação.

Por fim, para a métrica de cálculo utilizou-se acurácia para avaliação de eficiência no resultado.

4. RESULTADOS E DISCUSSÃO

4.1 Finalização do algoritmo.

Como resultado do estudo, o produto final, o software, foi denominado Claucia - representa o acrônimo relacionado a sua proposta de aplicação: Classificação de úlcera conforme inteligência artificial. Trata-se de um software para classificar feridas de forma automática considerando a Classificação da Universidade do Texas, sendo registrado junto ao no Instituto Nacional da Propriedade Industrial (INPI), sob registro de proteção número BR512022001637-0 (Anexo I).

Após a finalização da codificação (sequência de instruções da IA), ilustrada na figura 10, o algoritmo foi finalizado com o desenvolvimento de Interface Gráfica do Usuário e compilação dos códigos em formato executável (instalador para sistema operacional MS Windows), tornando assim o código em um programa de computador em versão beta (de avaliação).

A interface tem como função possibilitar a interação do usuário com a IA por meio de elementos gráficos. De tal modo, foram desenvolvidas janelas (área na tela que exibe informações do programa). Assim, criou-se cinco janelas (figura 11) as quais correspondiam a instalação, apresentação, menu de opções do sistema, seleção de imagem e saída de dados, além de um ícone para indicar que o programa está sendo iniciado.

A conversão do código em um arquivo a ser instalado e executado como um programa de janelas utilizou a ferramenta InnoSetup. Trata-se de um conversor de código aberto de algoritmo para pacotes de instalação (RUSSELL'S, 2022).

Com a finalização da versão de avaliação do programa, iniciou-se os testes de usabilidade e de comparação de resultados. O programa foi testado, previamente, por duas profissionais da área da saúde. Foram dadas instruções de instalação e usabilidade. O intuito foi que avaliassem o desempenho do programa e se a classificação, gerada pela IA, correspondia a classificação real realizadas por estas profissionais.

```

import os
import pathlib

import matplotlib.pyplot as plt
import numpy as np
import tensorflow as tf
from tensorflow import keras
from tensorflow.keras import layers
from tensorflow.keras.models import Sequential

dataset_url = os.path.abspath("./fotos")
data_dir = pathlib.Path(dataset_url)
image_count = len(list(data_dir.glob('*/*.jpg')))

print("Processando %d imagens do diretório de treinamento %s..."
      % (image_count, data_dir))

A
train_ds = tf.keras.preprocessing.image_dataset_from_directory(
    data_dir,
    validation_split=percentual_controle / 100,
    subset="training",
    seed=seed,
    image_size=(img_height, img_width),
    batch_size=batch_size,
    interpolation="bilinear"

B
val_ds = tf.keras.preprocessing.image_dataset_from_directory (
    data_dir,
    validation_split=percentual_controle / 100,
    subset="validation",
    seed=seed,
    image_size=(img_height, img_width),
    batch_size=batch_size,
    interpolation="bilinear"
)

C
model.compile(optimizer='adam',
              loss=tf.keras.losses.SparseCategoricalCrossentropy(
                  from_logits=True),
              metrics=['accuracy'])

model.summary()

history = model.fit(
    train_ds,|
    validation_data=val_ds,
    epochs=epochs
)

D
acc = history.history['accuracy']
val_acc = history.history['val_accuracy']
loss = history.history['loss']
val_loss = history.history['val_loss']
epochs_range = range(epochs)
plt.figure(figsize=(8, 8), num="Resultado do treinamento")
plt.subplot(1, 2, 1)
plt.plot(epochs_range, acc, label='Training Accuracy')
plt.plot(epochs_range, val_acc, label='Validation Accuracy')
plt.legend(loc='lower right')
plt.title('Training and Validation Accuracy')
plt.subplot(1, 2, 2)
plt.plot(epochs_range, loss, label='Training Loss')
plt.plot(epochs_range, val_loss, label='Validation Loss')
plt.legend(loc='upper right')
plt.title('Training and Validation Loss')

E
F

```

Figura 10. Exemplo da sequência de instruções que o algoritmo (programa) deve executar. (a) Importação de biblioteca de códigos e instruções para o funcionamento do algoritmo. (b) Leitura e cópia das imagens para o programa (importação das amostras). (c) Parâmetros para o treinamento da IA (Dataset). (d) Parâmetros para validação de resultados (Dataset de acurácia). (e) Treinamento da IA. (f) Exibição de dados do treinamento.

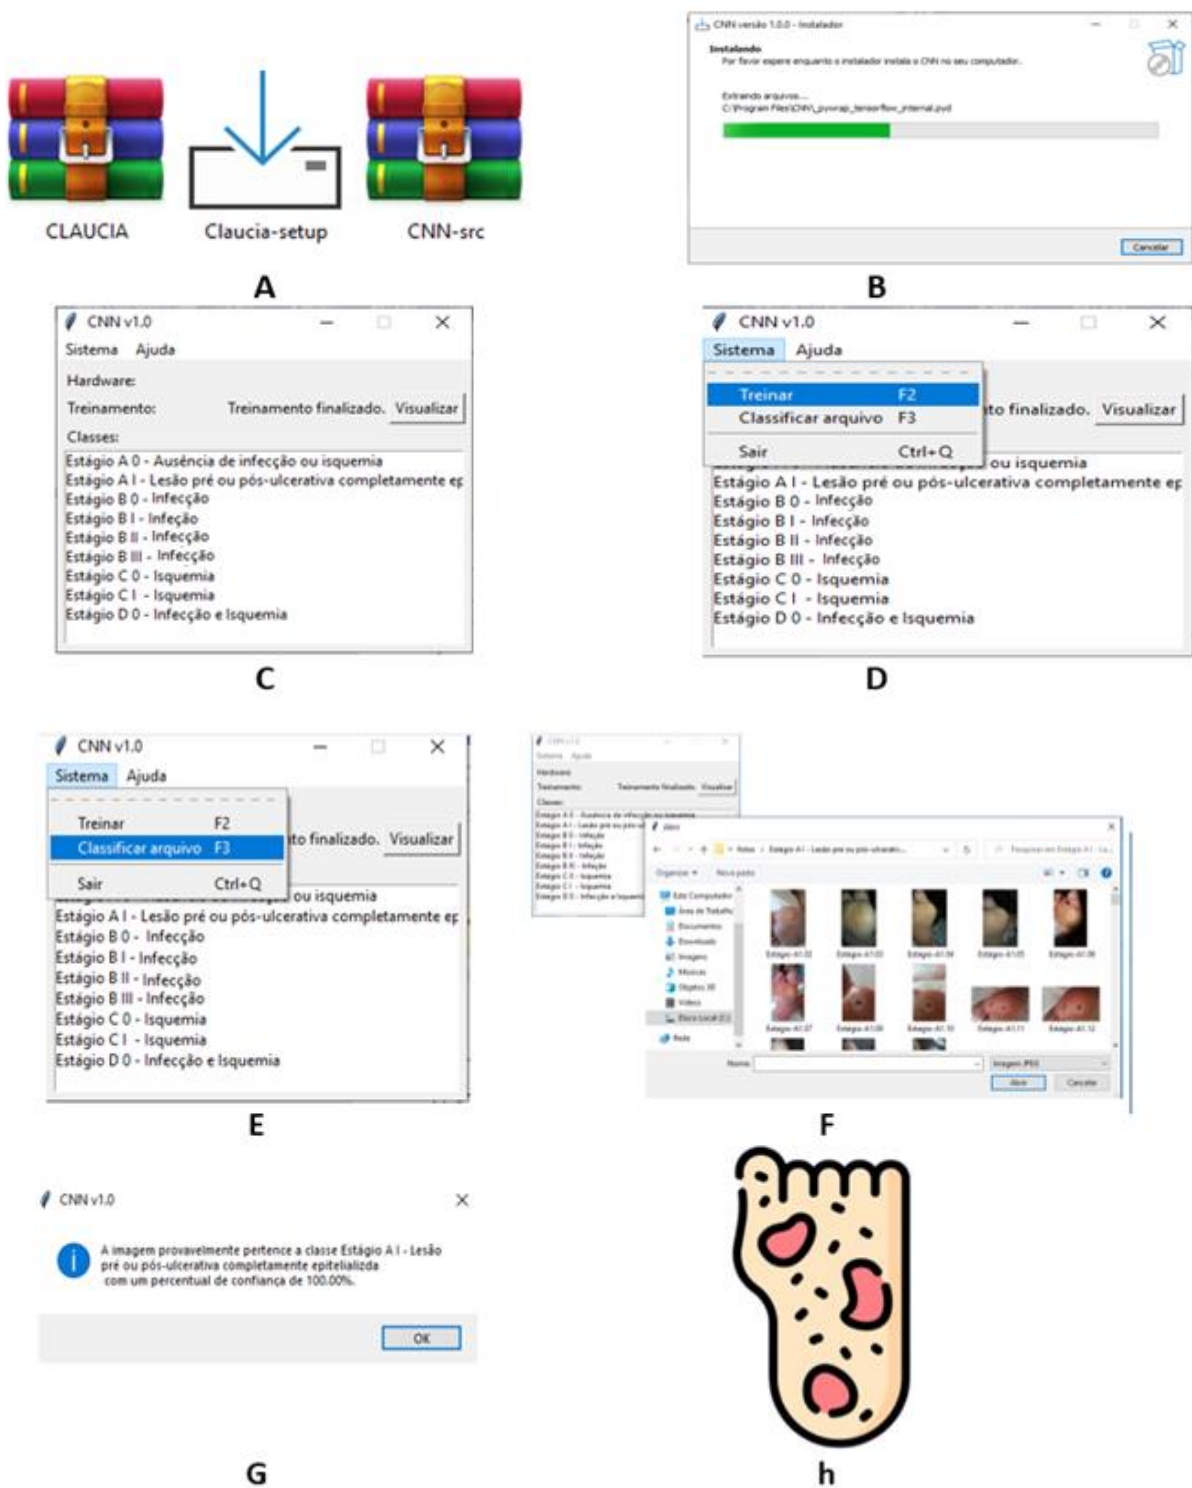


Figura 11. Interface de usuário do sistema de classificação de feridas usando inteligência artificial. (a) Arquivos de instalação (executáveis) (b) Janela de instalação. (c) Janela de apresentação. (d) Menu do sistema: função treinar. (e) Menu de sistema: função classificar. (f) Janela de seleção de arquivo para ser classificado. (g) Tela de saídas (resultados). (h). Ícone de Inicialização do programa.

4.2 Testes de funcionamento

Finalizada a primeira versão de testes do programa, foi iniciada a fase teste de funcionamento e ajuste de desempenho, bem como a análise de resultados. Esta análise foi realizada por profissionais de saúde. O uso do programa é realizado em duas etapas: uma vez iniciado o programa, o usuário seleciona a função de classificação e, em seguida, o registro fotográfico, conforme demonstrado na figura 12.

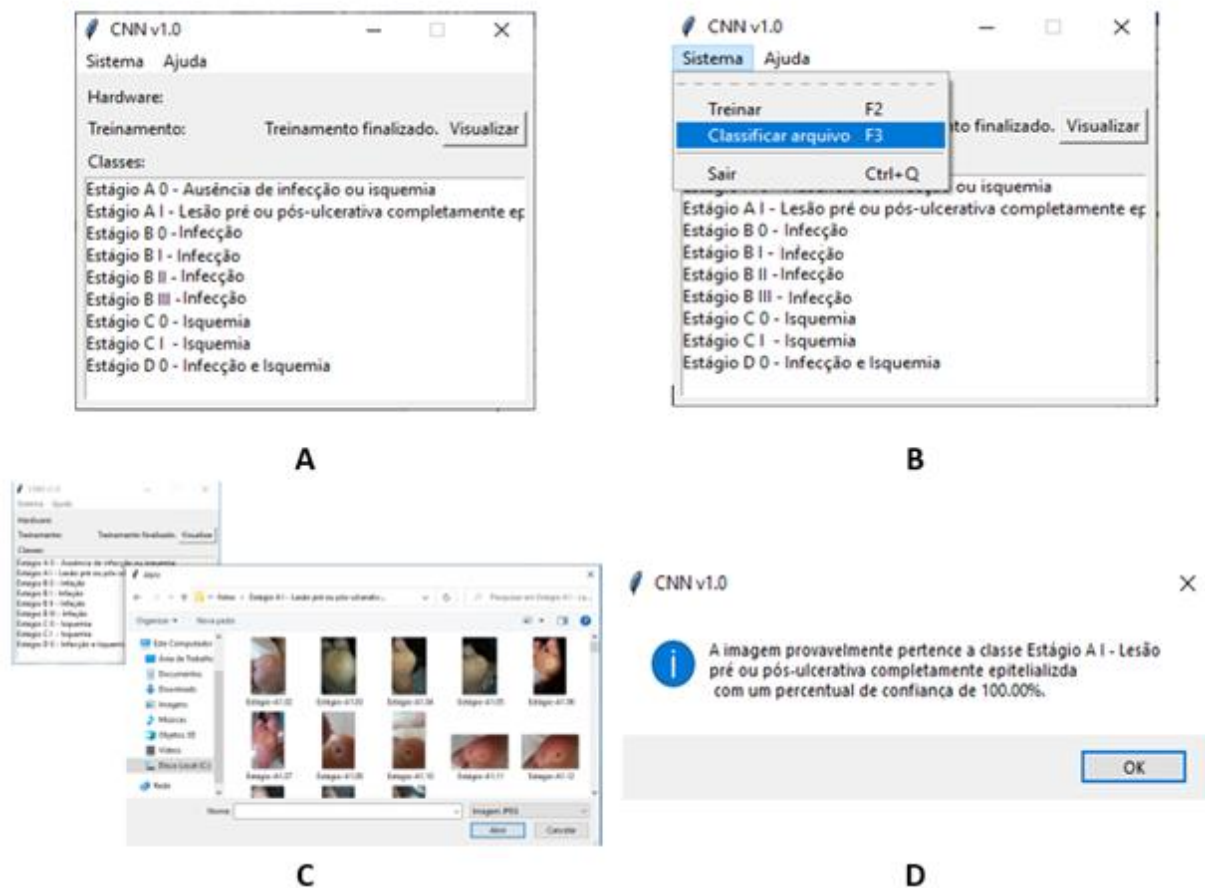


Figura 12. Passo a passo para uso do programa. (a). Tela inicial do programa. (b) Opção de classificação. (c) Seleção do registro fotográfico. (d). Resultado (classificação).

A avaliação de usabilidade e confiabilidade do sistema, realizada pelas pesquisadoras Luciene Ferreira dos Anjos e Luzia Sousa Ferreira, ambas enfermeiras, foi feita durante dois meses. Para isso, foi instalado o programa em seus

computadores pessoais das pesquisadoras e elas avaliaram a assertividade/acurácia do programa, baseado nos resultados gerados pelo programa e análise manual de correspondência de classificação.

Para tanto, foi cedido a cada uma das profissionais 277 registros do banco de dados do protocolo RAPHA® para cada que classificassem. Estas amostras foram selecionadas de forma aleatória e não rotulados e/ou identificados.

A avaliação de ambas chegou as seguintes considerações:

1. O programa apresentou a inicialização “pouco demorada”, contudo, uma vez iniciado, apresentou desempenho satisfatório (rápido) para a classificação.
2. Quando selecionado a função “treinar”, (destinada a realizar novos treinamentos da IA com novas amostras para o aprimoramento do sistema) as pesquisadoras alegaram que houve travamento do computador. Isto devido à baixa capacidade de processamento do equipamento, uma vez que em ambos os casos os testes foram realizados em notebook.

A função treinar foi usada para aprimorar a acurácia de classificação por IA. Para tanto necessita de uma capacidade grande de processamento e memória. Assim, a utilização dessa função é destinada àqueles que desejarem dar continuidade ao desenvolvimento e melhoria do projeto, não sendo imprescindível ao usuário final.

3. Por fim, em relação à classificação, principal objeto de análise, conforme relatado, o programa teve uma média de acertos consideravelmente superior aos de erros, sendo os erros relacionados ao que é considerado “ruídos” nas amostras.

Os ruídos referem-se as amostras que divergem do esperado, para que se verifique como o sistema se comporta ao inserir imagens que não são de feridas. Neste caso, o sistema retorna à classificação como “A-0”. Isto significa que após

análise, o programa não encontra sinais de UPD. Assim, o programa não consegue rejeitar a imagem por não conter padrões de ferida.

O sistema também gerou um relatório de cálculo de acurácia baseado no resultado apresentado, conforme apresentado na figura 13.




Figura 13. Métricas de desempenho do Aprendizado de Máquina: Relatório gerado pelo sistema. (a) Treinamento e validação de acurácia (representando a porcentagem de elementos classificados corretamente). (b) Treinamento e validação de perda (representa a distância entre o previsto e o real).

O exemplo acima demonstra as validações realizadas. No primeiro caso, a, o índice acurácia do treinamento (de forma simplificada, pode ser expressa da seguinte forma: $Acurácia = \frac{Qtd\ acertos}{Qtd\ Amostras} * 100$, ou seja, quanto maior a porcentagem, maior a confiabilidade do aprendizado).

Na segunda validação, b, foi realizada a verificação de perda, (diferença entre o resultado real e o obtido), ou seja, quanto maior o índice, menor a confiabilidade dos resultados, isto porque os resultados obtidos devem ser equivalentes aos reais. No exemplo apresentado, a perda só ocorre ao término do treinamento, onde não há mais resultados para comparação. Em outros termos, enquanto há treinamento, a acurácia

se mantém estável (exemplo a) e perda se mantém baixa, contudo, aumenta à medida que não há mais resultados a serem comparados com os reais. (exemplo b).

Ao confrontar os dois gráficos, pode-se verificar que o desempenho observado na rede (com elevados níveis nas curvas de treinamento e acurácias próximas ou igual à 100%) sugere que houve *overfitting*, mesmo utilizando *Dropout* (técnica que zera aleatoriamente uma porcentagem de neurônios nas camadas da rede neural a fim de evitar ou reduzir o *overfitting*).

Isso significa que o modelo se adaptou muito bem aos dados de treinamento, porém, não consegue generaliza bem para novos dados. Ou seja, o sistema “decorou” o conjunto de dados de treino, mas não aprendeu de fato o que diferencia aqueles dados para quando precisar enfrentar novos testes.

Este problema pode ter ocorrido devido a alguns fatores, como complexidade da rede e número limitado de amostras. Em outras palavras, ao analisar as curvas de aprendizado, nota-se que estas estão se distanciando, o que indica que o conjunto de dados de teste não conseguiu atingir o poder de generalização necessária classificação correta de novas imagens, necessitando de uma quantidade maior de amostras para refinamento do aprendizado.

Ao investigar propostas dedicadas a aplicação de tecnologia para UPD, a maior parte dos estudos tinham como foco à prevenção e detecção precoce de UPD por meio de aplicativos de smartphones (Tabela 3). Tais aplicativos funcionam utilizando recursos do aparelho, como sensores, câmera etc., e funcionalidades, como termometria³.

As funcionalidades variam entre monitoramento dos pés por meio de análise de fotos da planta do pé, análise preventiva e avaliações de risco de pé diabético. Ainda, são disponibilizadas funções voltadas ao autocuidado, com instruções sobre cuidados com o pé, diário interativo, alarmes, metas, exercícios para pés e tornozelos, dentre outros.

³ O surgimento de UPD são precedidas de aumento da temperatura dérmica local pela inflamação e destruição de células enzimática do tecido decorrente do desequilíbrio pressão-atividade, somado ao estresse, anormalidades biomecânicas e perda sensorial neuropática. A diferença de temperatura de 2,2°C entre o mesmo ponto de ambos os pés supõe risco de ulceração iminente. De tal modo, A termometria pode auxiliar na identificação precoce de UPD (ARÁUJO et al., 2022)

Tabela 3. Aplicativos para smartphones destinados ao monitoramento e prevenção de úlcera de pé diabético.

Autores	Nome do Aplicativo	Função do aplicativo	Principais resultados
(DUTTA; DUTTA, 2013)	SoleSCAN	Monitoramento online do pé por meio de palmilha que registra fotos e transfere as informações para um servidor de dados.	O aplicativo foi considerado uma boa estratégia de prevenção, pois permite a detecção precoce de possíveis formações de calos e úlceras nos pés.
(LAZO-PORRAS <i>et al.</i> , 2016)	TempStat	Capturar imagens térmicas dos pés	A termometria pode reduzir a incidência de pé diabético. O aplicativo apresentou abordagem preventiva inovadora e de baixo custo.
(FRAIWAN; NINAN; AL-KHODARI, 2018)	FLIR ONE	Obter imagens térmicas, processá-las e analisá-las para prever ulceração.	O sistema móvel foi bem-sucedido na identificação do aumento de temperatura dos pés e possibilita intervenções precoces para prevenir o pé diabético.
(PLODERER <i>et al.</i> , 2018)	My Foot Care	Destaca-se metas pessoais para ajudar a motivar os pacientes para o autocuidado e fornece lembretes para decretar o cuidado regular.	O aplicativo tem potencial prevenir a prevenção e no tratamento de úlceras nos pés de pessoas com diabetes.
(REYZELMAN <i>et al.</i> , 2018)	Stand-Alone	Gerar alertas quando os pés do usuário mostram aumento de temperatura	O monitoramento contínuo da temperatura dos pés apresentou-se como uma abordagem promissora de sistema de alerta para intervir de maneira precoce no risco de desenvolvimento de pé diabético
(YAP <i>et al.</i> , 2018)	FootSnap	Obter imagens da planta do pé.	O aplicativo foi bem-sucedido em padronizar a aquisição de fotos da planta do pé para observar parâmetros dos pés e mostrou-se significativo na prevenção e na gestão de patologias do pé diabético.
(FERREIRA <i>et al.</i> , 2019)	SoPeD	Ofertar recomendações de autocuidados com os pés, diabetes, pé diabético e exercícios de pé e tornozelo.	O aplicativo foi validado e apresentou alto grau de concordância entre os especialistas, profissionais e usuários, como aplicativo que pode ajudar na prevenção do pé diabético.
(MING <i>et al.</i> , 2019)	SPDFA	Medir temperatura do pé, fornece documentação fotográfica, e avaliar o bem-estar (qualidade de vida), utilizando um diário interativo	O aplicativo provou ser uma das soluções mais rentáveis para a detecção precoce de úlceras do pé diabético.
(VËSCOVI <i>et al.</i> , 2017)	CuidarTech	Avaliação e classificação do risco de pé diabético	O aplicativo, por meio de avaliação dos enfermeiros, mostrou-se confiável, adequado e eficiente para classificação do risco e prevenção do pé diabético

Fonte: (DABÓ *et al.*, 2020)

Nosso grupo de pesquisa, tem atuado em uma abordagem com propostas similares às apresentadas nestes estudos, vinculadas ao Projeto RAPHA®, Tabela 4. Os estudos basearam-se na metodologia de segmentação de imagem, uma técnica usada para conversão de uma imagem em múltiplos objetos de análise, isso permite que os algoritmos consigam encontrar regiões homogêneas na imagem (por exemplo,

com a mesma cor) e a partir de medidas de distância ou probabilidade de um pixel pertencer a uma classe específica, consiga aplicar as métricas de análise, conforme exemplificado na figura 14.

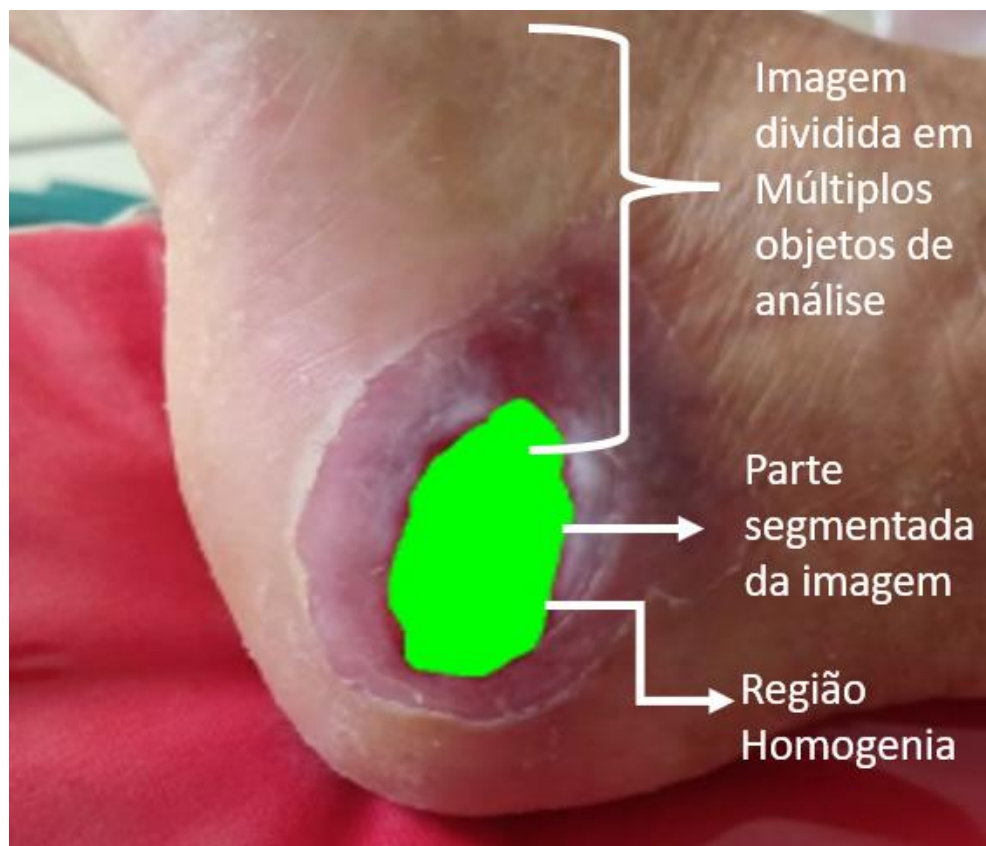


Figura 14. Exemplo de imagem de úlcera com segmentação, com adaptações. Fonte: (SILVA, 2020).

Tabela 4. Estudos de segmentação relacionados à análise de imagens de feridas.

Autores	Nome do estudo	Objetivo	Resultados
(SOUSA, 2019)	Dimensionamento e análise de feridas utilizando o método de segmentação pelo método <i>simple linear iterative clusterin</i>	Por meio de técnicas de processamento digital de imagens, realizou-se o dimensionamento de feridas e a classificação de regiões por cores	A ferramenta gera resultados compatíveis com métodos de segmentação automática, porém com a vantagem de permitir ao profissional de saúde atuação direta em manipular a região segmentada.
(SILVA, 2020)	Desenvolvimento de base de dados de imagens, classes e mensuração de úlceras do pé diabético para técnicas de classificação e ferramentas de auxílio a diagnóstico.	Desenvolvimento de base de dados de imagens, classes e mensuração de úlceras do pé diabético para técnicas de classificação e ferramentas de auxílio a diagnóstico.	As imagens digitais originais e segmentadas manualmente compõem a base de dados. Este conjunto de informações da lesão serve como modelo para possibilitar a automatização por processamento de imagens.

Em relação a aplicação da Inteligência Artificial para UPD, os estudos encontrados têm foco na prevenção, caracterização visual para auxílio ao diagnóstico e comparação de arquitetura (redes neurais). Os estudos encontrados estão listados na tabela 5. Não foram encontradas quaisquer propostas de programas para classificação de úlcera de acordo com a Universidade do Texas, o que demonstra o ineditismo e relevância deste trabalho.

Tabela 5. Lista de estudos que sobre o uso de Aprendizado de Máquina para Úlceras de Pé Diabético.

Autores	Nome do estudo	Objetivo	Resultados
(SANTOS <i>et al.</i> , 2021)	Uma Avaliação de Arquiteturas de Aprendizado Profundo para a Classificação de Úlceras do Pé Diabético	Estudo comparativo do desempenho de diversas arquiteturas de aprendizado profundo pré-treinadas na classificação de imagens de úlceras do pé diabético.	índice Kappa (a técnica de medida de exatidão que pode ser utilizada para determinar se uma matriz de erro é significativamente diferente da outra.) atingiu valores considerados "Excelentes". Contudo, ainda é necessário aprimorar o uso das técnicas analisadas.
(BARBOSA; FERREIRA; LOPES, 2021)	Uso de Inteligência Artificial para predição e prevenção de pé diabético	Comparar as principais ferramentas de inteligência artificial (IA) aplicadas na predição e prevenção do pé diabético, bem como comparar as vantagens em relação aos métodos clássicos de prevenção do pé diabético.	Dentre as limitações da área destacam-se: necessidade de métodos baseados em aprendizado contínuo, que possam incorporar mudanças nos dados sem esquecer o aprendizado acumulado; necessidade de métodos que lidam com ruído nos rótulos e informações faltantes.
(JUNIOR, 2021)	Estudo da automação para auxílio da caracterização e diagnóstico de feridas por aplicação digital	Estabelecer diferentes conjuntos de técnicas envolvendo processamento de imagens digitais e visão computacional no intuito de caracterizar aspectos visuais de feridas obtidas por imagens digitais, auxiliando no diagnóstico e tomada de decisão por profissionais especializados	O modelo desenvolvido obteve acertos de 67%, sendo necessárias melhorias e maiores testes para que a eficácia do software possa ser considerada satisfatória.
(MARQUES, 2014)	Segmentação e classificação automática de úlceras	Criar um programa que possa facilitar o acompanhamento e fornecer dados sobre a evolução da cicatrização da úlcera por meio da segmentação e classificação.	O trabalho foi desenvolvido utilizando o software MATLAB e técnicas de processamento digital de imagens.

Dentre as técnicas mais utilizadas está a segmentação de imagens, que consiste em dividir uma imagem digital em múltiplas regiões de pixels, com o objetivo de simplificar uma imagem para análise. Assim, é possível por comparação de imagens perceber mudanças em determinadas regiões e prever o aparecimento de

sinais de ulceração. Dentre as principais ferramentas utilizadas destacam-se os softwares ImageJ®, IBM MatLab® e técnicas de Aprendizado de Máquina.

Ao se explorar “classificação de úlceras de pé diabético”, notou-se que esta é uma temática pacificada, no sentido de já ter sua normatização padronizada. Conforme explicado no tópico “2.4-Classificação das feridas conforme a Universidade do Texas” (pág. 10), atualmente o sistema de saúde adota essa classificação como padrão (SBD, 2020). Além desta há, como explicado no tópico, outras formas classificatórias tais como: Meggitt-Wagner; Site; Ischaemia, Neuropathy; Bacterial infection, Area and Depth (SINBAD); Wound, Ischemia, Foot Infection (WIFI).

Classificar a ferida consiste em avaliar a lesão e identificar o grau de comprometimento das estruturas teciduais e com base nessa análise, categorizar em uma escala padronizada. Tem como papel orientar o diagnóstico para estabelecer a cobertura adequada a cada ferida, além do registro da evolução da úlcera e, por fim, garantir que qualquer profissional de saúde possa entender o estado clínico dando continuidade ao tratamento.

Portanto, classificação de úlcera, conforme o padrão da Universidade do Texas adotado pelo SUS, demonstra ser uma ferramenta inovadora em termos de ferramenta de auxílio ao diagnóstico e escolha da abordagem terapêutica. Sua popularização pode representar um avanço no tratamento, uma vez que é facilitada a utilização para o usuário. A análise é realizada de forma rápida e impessoal, o que representa uma vantagem, uma vez que o ambiente de ambulatório pode influenciar na classificação devido ao escasso tempo para a avaliação e a aglomeração de pacientes que necessitam de atendimento imediato.

Assim, esse trabalho teve como objetivo o desenvolvimento de uma ferramenta de baixo custo e alta acurácia para auxiliar o diagnóstico e evolução de UPD, por meio da classificação utilizada pelos serviços públicos de saúde. Além disso, foi possível ir além do objetivo geral estabelecido (pág. 3 item 1.1.1) que visava desenvolver um algoritmo baseado em Aprendizado de Máquina capaz de classificar úlceras de pé diabético, a partir de registros fotográficos. Com efeito, foi apresentado como produto deste estudo não somente o algoritmo como também uma versão inicial do classificador com testes preliminares de execução e validação de resultados realizados por profissionais da área da saúde.

5. CONCLUSÃO

Ao término do estudo, obteve-se um produto de inovação tecnológica: uma ferramenta para treinamento e teste que pode ser efetuado por profissionais não especializados em treinamento de máquina. De tal modo, é possível afirmar que o programa atendeu aos requisitos desejados dentro do escopo delimitado, demonstrando potencial para ser implementado como um instrumento de auxílio ao diagnóstico confiável.

Partindo da premissa que um bom trabalho em pesquisa não deve se encerrar ao atingir o recorte proposto, mas, em teoria, se engrandece ao abrir novas possibilidades e questionamentos a partir de sua proposta. De tal forma, pode-se afirmar que a maior contribuição desse estudo não está somente na automatização de uma tarefa essencialmente humana, mas na verificação da utilidade e impacto dessa ferramenta tanto para os profissionais de saúde quanto para os usuários do SUS e, não menos importante, nas possibilidades de implementação que essa ferramenta abriu para trabalhos futuros, como por exemplo, implementar aprendizado por reforço a partir de um servidor que colete novas amostras advindas do uso em ambiente ambulatorial periódico.

Em relação aos resultados obtidos, observou-se que a curva de treinamento obteve um desempenho alto ao mesmo tempo em que há uma queda dos dados que não utilizados, ou seja, a rede neural não está conseguindo generalizar para dados externos. Na prática, isso significa que se for dado ao sistema imagens diferenciadas, possivelmente o resultado poderá estar incorreto. Isso pode ser atribuído ao volume insuficiente de amostras utilizadas para o desenvolvimento em face da complexidade exigida da rede. Para melhorar o desempenho, foi aplicada a técnica de rotação e as saídas da rede foram ajustadas de forma a coincidir com as classes da base de dados, contudo, o volume ainda se manteve insuficiente para treinar a rede de forma satisfatória.

Outro ponto complementar a esse ponto é o fato do universo amostral não ter amostras de todas as classes. Sendo desenvolvida com as seguintes classes: Estágio A0 e A1 (trata de ausência de infecção ou isquemia), B0, B1 e B111 (feridas com Infecção), C0 e C1 (Isquemia), e por fim D0, que trata de Infecção com Isquemia. De tal modo, caso seja dada uma imagem de uma classe não pertencente ao treinamento, a IA

retornará uma saída com erro. No mesmo sentido, assim, o programa não consegue rejeitar a imagem por não conter padrões de ferida. De tal modo, novas versões poderão implementar soluções para estes quesitos.

5.1 Trabalhos futuros

Conforme exposto, a versão inicial da Claucia não contempla todas as classes. Assim, as versões posteriores terão necessariamente que aumentar de um conjunto amostral com todas as classes, a fim de inserir novos dados e melhorar o desempenho nas já desenvolvidas. Da mesma forma, sugere-se a aplicação de técnicas de *Data Augmentation* (métodos para gerar novos exemplares de dados de treinamento a partir dos existentes, seja por rotação da imagem, modificação a perspectiva, distorção, achatamento, alongamento ou translação) a fim de aumentar a capacidade de generalidade da rede.

Eventualmente, para maior robustez do software e implementação do sistema, sugere-se a criação um sistema em rede que possibilite a aprendizagem por reforço de forma a melhorar a generalização da rede a partir de um agrupamento de novas amostras obtidas em ambiente ambulatorial. Assim, ao se obter um grande volume de dados, pode-se aplicar outras técnicas (além do *Data Augmentation*), como transformação do espaço de cores para melhorar o processamento.

A métrica utilizada neste estudo predominante foi a acurácia (proporção de acerto), contudo, para efeito de diagnóstico, somente a lógica baseada em acertos e erros podem ser insuficientes, uma vez o resultado apresentado pelo sistema pode estar de acordo com o aprendido, mas não corresponde à realidade, gerando assim um falso positivo ou falso negativo. O que é reforçado pelo fato de o modelo não comportar todas as classes da Universidade do Texas. Assim, se faz necessário, para as próximas versões, implementar métricas, como precisão, sensibilidade (*recall* ou revocação), especificidade, valores preditivos positivo e negativo, razão de verossimilhança ou outras.

Da mesma forma, sugere-se implementar funções que possibilite o paciente e cuidador a fazer anotações que auxilie o diagnóstico, como odor, características que

não é possível avaliar por imagem ou mesmo um questionário para detalhar a avaliação da ferida.

Para além do desenvolvimento, o trabalho possibilita e sugere a realização de estudos de revisão sistemática sobre as ferramentas desenvolvida para a classificação de Úlceras de Pés Diabéticos, para aprofundamento do tema de forma a atualizar e descrever com maior detalhamento os estudos sobre o tema.

Por fim, o programa, enquanto classificador, possibilita o desenvolvimento de um sistema de maior complexidade, de forma a agregar novas funcionalidades, como módulos de mensuração do tamanho de feridas ou de comparação de classificações e tamanhos em um período determinado, a fim de estimar a resposta do organismo ao tratamento. Além disso, é possível fazer a integração do programa com outras plataformas, como Android e IOS para smartphones. Neste sentido, sugere-se a continuidade do desenvolvimento deste trabalho para uma versão final e aplicável para uso comercial.

6. REFERÊNCIAS BIBLIOGRÁFICAS

ALVES, Gisely. Entendendo redes convolucionais (cnns). 2018. <https://medium.com/neuronio-br/entendendo-redes-convolucionais-cnns-d10359f21184>. Acessado em, [s. l.], v. 24, p. 12, 2019.

ARÁUJO, Açucena Leal de; NEGREIROS, Francisca Diana da Silva; FLORÊNCIO, Raquel Sampaio. Efeito da termometria na prevenção de úlceras de pé diabético: revisão sistemática com metanálise. **OLIVEIRA, Shérica Karanini Paz de SILVA, Ana Roberta Vilarouca da MOREITA, Thereza Maria Magalhães**, [s. l.], 2022. Disponível em: <https://www.scielo.br/j/rlae/a/VqYcbBFyDDgdGm8zD6Zdpwf/?format=pdf&lang=pt>.

BARBOSA, Ana Claudia Honório; FERREIRA, DANTON D.; LOPES, Maria Helena. Uso de Inteligência Artificial para predição e prevenção de pé diabético. *In*: PARISI, Maria Cândida; LEITE, Círcia Raquel Maia; ROSA, Mário Fabrício Fleury (org.). **Interdisciplinaridade no contexto das doenças dos pés no diabetes**. 1. ed. Brasília: [s. n.], 2021. p. 15–40. *E-book*. Disponível em: https://www.researchgate.net/publication/354338947_Uso_de_Inteligencia_Artificial_para_predicao_e_prevencao_de_pe_diabetico.

BERTONHI, Laura Gonçalves. Aspectos clínicos, tratamento e conduta dietoterápica. **Diabetes mellitus tipo 2**, [s. l.], 2018.

BRASIL. **Manual do pé diabético: estratégias para o cuidado da pessoa com doença crônica**. [S. l.]: Ministério da Saúde Brasília, DF, 2016.

BRASIL. **Protocolo de Cuidado com os Pés de Pessoas com Diabetes Mellitus na SES/DF**. [S. l.: s. n.], 2018. Disponível em: <http://www.saude.df.gov.br/wp-conteudo/uploads/2018/04/Protocolo-Pé-Diabético-1.pdf>.

CERQUEIRA, Lorena de Oliveira *et al.* Classificação Wifl: o novo sistema de classificação da Society for Vascular Surgery para membros inferiores ameaçados, uma revisão de literatura. **Jornal Vascular Brasileiro**, [s. l.], v. 19, 2020.

CORTEZ, Diogo Eugênio da Silva. Desenvolvimento de um sistema de controle de tráfego inteligente baseado em visão computacional. **Programa de Pós-graduação em Tecnologia da Informação do Instituto MetrÓpole Digital da Universidade Federal do Rio Grande do Norte**, [s. l.], v. Dissertaçã, n. Engenharia de Software, 2022. Disponível em: https://repositorio.ufrn.br/bitstream/123456789/47158/1/Desenvolvementosistemacontrole_Cortez_2022.pdf.

CUNHA, João; DUTRA, Rosimar; SALOMÉ, Geraldo. Elaboração de algoritmo para avaliação e tratamento de ferida. **Revista ESTIMA**, [s. l.], 2018.

DA SILVA, Vanessa Abreu *et al.* **Manual de processos de trabalho do núcleo de estomaterapia: Estomias, feridas e incontinência**. Campinas: [s. n.], 2016. Disponível em: <https://intranet.hc.unicamp.br/manuais/estomaterapia.pdf>.

DA SILVA FILHO, Carlos R M *et al.* Avaliação da bioatividade dos extratos de cúrcuma (*Curcuma longa* L., Zingiberaceae) em *Artemia salina* e *Biomphalaria glabrata*. **Revista Brasileira de Farmacognosia**, [s. l.], v. 19, p. 919–923, 2009.

DABÓ, Sabado Gomes *et al.* Tecnologias digitais na prevenção de pé diabético: uma revisão sobre aplicativos móveis. **ESTIMA Brazilian Journal of Enterostomal Therapy**, [s. l.], 2020. Disponível em: https://www.revistaestima.com.br/index.php/estima/article/view/870/_1.

DUTTA, Arindam; DUTTA, Anirban. soleSCAN - mobile phone based monitoring of foot sole for callus formation and the shoe insole for pressure “hot spots”. **IEEE Point-of-Care Healthcare Technologies (PHT)**, [s. l.], p. 339–342, 2013. Disponível em: <https://ieeexplore.ieee.org/abstract/document/6461354>.

EGLE, LEONARDI. **Mapa do diabetes no Brasil para a farmacia clinica**. [S. l.: s. n.], 2021. Disponível em: <https://ictq.com.br/varejo-farmaceutico/745-o-mapa-do-diabetes-no-brasil>.

FAVRETO, F J L *et al.* O papel do enfermeiro na prevenção, avaliação e tratamento das lesões por pressão. **RGS [Internet]**, [s. l.], v. 17, n. 2, p. 37–47, 2017.

FERREIRA, Ricardo Cardenuto. Pé diabético. Parte 1: Úlceras e Infecções. **Revista Brasileira de Ortopedia**, [s. l.], v. 55, p. 389–396, 2020.

FERREIRA, Jane S. S. P. Ferreira *et al.* Rehabilitation technology for self-care: Customised foot and ankle exercise software for people with diabetes. [s. l.], p. 1–10. *Journal of Podiatry*, 2019. Disponível em: <https://doi.org/10.1371/journal.pone.0218560>.

FRAIWAN, Luay; NINAN, Jolu; AL-KHODARI, Mohanad. Aplicativo móvel para detecção de úlceras. **open biomedical engineering journal**, [s. l.], v. 12, p. 16–26, 2018. Disponível em: <https://openbiomedicalengineeringjournal.com/VOLUME/12/PAGE/16/>.

GARBUIO, Danielle Cristina *et al.* Instrumentos para avaliação da cicatrização de lesões de pele: revisão integrativa. **Revista Eletrônica de Enfermagem**, [s. l.], v. 20, 2018.

GÉRON, Aurélien. **Mãos à Obra: Aprendizado de Máquina com Scikit-Learn & TensorFlow**. [S. l.]: Alta Books, 2019.

GOMES, D dos S. Inteligência Artificial: conceitos e aplicações. **Olhar Científico**, [s. l.], v. 1, n. 2, p. 234–246, 2010.

GUIMARÃES, Guilherme dos Anjos. **Proposta de um controlador orgânico e análise teórico-experimental por bond graph e regressão polinomial de feridas de pé diabético a partir da aplicação do protocolo Rapha**. 2019. - Programa de Pós-Graduação em Engenharia Biomédica, Universidade de Brasília, Campus Gama, [s. l.], 2019. Disponível em: https://repositorio.unb.br/bitstream/10482/38169/1/2019_GuilhermedosAnjosGuimaraes.pdf.

HAYKIN, Simon. **Redes neurais: princípios e prática**. [S. l.]: Bookman Editora, 2007.

JORGE, Amanda Rosa Ferreira. Dados Epidemiológicos Nacionais de Amputação e Proposta de Dispositivo para Treinamento de Usuários de Próteses de Membro Superior. **Universidade Federal de Uberlândia**, [s. l.], p. 84, 2020.

Disponível em:
<https://repositorio.ufu.br/bitstream/123456789/30505/3/DadosEpidemiologicosAmputação.pdf>.

JUNIOR, Robson Michiades Neto. Estudo da automação para auxílio da caracterização e diagnóstico de feridas por aplicação digital. [s. l.], n. CENTRO UNIVERSITÁRIO SAGRADO CORAÇÃO, p. 51, 2021. Disponível em: <https://repositorio.unisagrado.edu.br/bitstream/handle/143/1/ESTUDO DA AUTOMAÇÃO PARA AUXILIO.pdf>.

KAPLAN, Andreas; HAENLEIN, Michael. Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. **Business Horizons**, [s. l.], v. 62, n. 1, p. 15–25, 2019.

KINGMA, Diederik P.; BA, Jimmy Lei. Adam: A method for stochastic optimization. **3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings**, [s. l.], 2015.

KOVÁCS, Zsolt László. **Redes neurais artificiais**. [S. l.]: Editora Livraria da Física, 2002.

KUSHIBIKI, Toshihiro *et al.* Low reactive level laser therapy for mesenchymal stromal cells therapies. **Stem cells international**, [s. l.], v. 2015, 2015.

LAZO-PORRAS, Maria *et al.* Implementação da termometria do pé mais mHealth para prevenir úlceras do pé diabético: protocolo de estudo para um ensaio clínico randomizado. **BMC Parte da Natureza Springer**, [s. l.], n. Julgamentos, 2016. Disponível em: <https://doi.org/10.1186/s13063-016-1333-1>.

LUCOVEIS, Maria do Livramento Saraiva *et al.* Grau de risco para úlceras nos pés por diabetes: avaliação de enfermagem. **Revista Brasileira de Enfermagem**, [s. l.], v. 71, p. 3041–3047, 2018.

LUDERMIR, Teresa Bernarda. Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências. **Estudos Avançados**, [s. l.], v. 35, p. 85–94, 2021.

MACIEL, Ricardo Pires. Desenvolvimento de uma Abordagem Computacional para Detecção Facial e Rastreamento do Sistema Visual da População Infantil. **Universidade Federal de Santa Catarina**, [s. l.], n. Trabalho Conclusão do Curso de Graduação em Tecnologias da Informação, p. 48, 2022. Disponível em: <https://repositorio.ufsc.br/bitstream/handle/123456789/233731/TCC-RicardoMaciel-Final.pdf?sequence=2&isAllowed=y>.

MARQUES, Marina Pinheiro. Segmentação e classificação automática de úlceras. [s. l.], n. Universidade de Brasília, 2014. Disponível em: <https://bdm.unb.br/handle/10483/9275>.

MCCULLOCH, Warren S; PITTS, Walter. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, [s. l.], v. 5, n. 4, p. 115–133, 1943.

MING, Antão *et al.* Study protocol for a randomized controlled trial to test for preventive effects of diabetic foot ulceration by telemedicine that includes sensor-equipped insoles combined with photo documentation. **BMC**, [s. l.], p. 20:521, 2019. Disponível em: <https://trialsjournal.biomedcentral.com/articles/10.1186/s13063-019-3623-x>.

NOURI, Dorra *et al.* Colour and multispectral imaging for wound healing evaluation in the context of a comparative preclinical study. *In:* , 2013. **Medical Imaging 2013: Image Processing**. [S. l.: s. n.], 2013. p. 866923.

PLODERER, Bernd *et al.* Promoting Self-Care of Diabetic Foot Ulcers Through a Mobile Phone App: User-Centered Design and Evaluation. **JMIR Diabetes**, [s. l.], p. 3(4):e10105, 2018. Disponível em: <https://diabetes.jmir.org/2018/4/e10105>.

PRIMO, Alex Fernando Teixeira *et al.* O uso de chatterbots na educação à distância. **LEC/UFRGS Projeto: Rede Telemática para Formação de Educadores MEC/OEA. Porto Alegre**, [s. l.], 2000.

REGES, Jonas Platini *et al.* Controle Fuzzy de Robô Diferencial. **HOLOS**, [s. l.], v. 7, p. 98–109, 2017.

REYZELMAN, Alexander M *et al.* Continuous Temperature-Monitoring Socks for Home Use in Patients With Diabetes: Observational Study. **J Med Internet Res**, [s. l.], p. 20(12):e12460, 2018. Disponível em: url: <https://www.jmir.org/2018/12/e12460>.

ROSA, Mário Fabrício Fleury *et al.* Desenvolvimento de tecnologia dura para tratamento do pé diabético: um estudo de caso na perspectiva da saúde coletiva. **Saúde em Debate**, [s. l.], v. 43, p. 87–100, 2020.

ROSA, Suélia de Siqueira Rodrigues Fleury *et al.* **Regeneration of Diabetic Foot Ulcers Based on Therapy with Red LED Light and a Natural Latex Biomembrane**. [S. l.]: Springer, 2019. Disponível em: https://link.springer.com/article/10.1007/s10439-019-02220-5#auth-G__A_-Guimar_es.

ROSENBLATT, Frank. **The perceptron, a perceiving and recognizing automaton Project Para**. [S. l.]: Cornell Aeronautical Laboratory, 1957.

SANTANA, Thamís Fernandes. **Análise da inflamação e estresse oxidativo no processo de cicatrização tecidual após o uso combinado de lipossomas com curcumina em biomembranas de látex natural e ledterapia para regeneração tecidual em portadores de úlcera diabética**. 2021. - Programa de Pós-Graduação em Engenharia Biomédica, Universidade de Brasília, Campus Gama, [s. l.], 2021. Disponível em: https://repositorio.unb.br/bitstream/10482/41351/1/2021_ThamisFernandesSantana.pdf.

SANTOS, Francisco *et al.* Uma Avaliação de Arquiteturas de Aprendizado Profundo para a Classificação de Úlceras do Pé Diabético. *In*: , 2021. (SIMPÓSIO BRASILEIRO DE COMPUTAÇÃO APLICADA À SAÚDE, Org.) **Anais [...]**. [S. l.: s. n.], 2021. Disponível em: <https://sol.sbc.org.br/index.php/sbcas/article/view/16076>.

SBD. **Diretrizes da sociedade brasileira de diabetes**. São Paulo: Sociedade Brasileira de Diabetes, 2014. v. 2015

SBD, Sociedade Brasileira de Diabetes. sbd lança nova edição do manual

cuidados com os pés em pessoas com diabetes. [s. l.], 2020. Disponível em: <https://diabetes.org.br/e-book/cuidados-com-os-pes-em-pessoas-com-diabetes/>.

SCHAPER, N C *et al.* The International Working Group on the Diabetic Foot. **IWGDF Guidelines on the prevention and management of diabetic foot disease**, [s. l.], 2019.

SIDDIQUE, Nazmul; ADELI, Hojjat. **Computational intelligence: synergies of fuzzy logic, neural networks and evolutionary computing**. [S. l.]: John Wiley & Sons, 2013.

SILVA, Mayla dos Santos. Desenvolvimento de base de dados de imagens, classes e mensuração de úlceras do pé diabético para técnicas de classificação e ferramentas de auxílio a diagnóstico. [s. l.], n. Dissertação (Mestrado em Engenharia Biomédica) – Programa de pós-graduação em Engenharia Biomédica, Universidade de Brasília, Brasília, 2020. Disponível em: <https://repositorio.unb.br/handle/10482/39018#:~:text=Desenvolvimento de base de dados de imagens%2C classes e Mmensuração,de Brasília%2C Brasília%2C 2020.>

SIMÕES, Marcelo Godoy; SHAW, Ian S. **Controle e modelagem fuzzy**. [S. l.]: Editora Blucher, 2007.

SIQUEIRA, Ana Kelly Américo *et al.* O enfermeiro na promoção da saúde frente ao pé diabético na atenção básica de saúde. **Brazilian Journal of Health Review**, [s. l.], v. 2, n. 4, p. 3164–3173, 2019.

SOUSA, Danovan Martins de. Dimensionamento e análise de feridas utilizando o método de segmentação SLIC. [s. l.], n. trabalho de Conclusão de Curso (graduação)—Universidade de Brasília, Brasília, 2019. Disponível em: <https://bdm.unb.br/handle/10483/26042>.

THOMAS, R L *et al.* IDF Diabetes Atlas: A review of studies utilising retinal photography on the global prevalence of diabetes related retinopathy between 2015 and 2018. **Diabetes research and clinical practice**, [s. l.], v. 157, p. 107840, 2019.

TURING, Alan M. Computing machinery and intelligence. *In*: PARSING THE

TURING TEST. [S. l.]: Springer, 2009. p. 23–65.

VÊSCOVI, Selma de Jesus Bof *et al.* Aplicativo móvel para avaliação dos pés de pessoas com diabetes mellitus. **Acta Paul Enferm**, [s. l.], v. 30, n. 607, p. 13, 2017. Disponível em: <https://www.scielo.br/j/ape/a/d9rKvFHtsrjqwyXgbjqvL5K/?format=pdf&lang=pt>.

WERNER, Betina *et al.* Uso prático da imuno-histoquímica em patologia cirúrgica. **Jornal Brasileiro de Patologia e Medicina Laboratorial**, [s. l.], v. 41, p. 353–364, 2005.

YAP, Moi Hoon *et al.* A New Mobile Application for Standardizing Diabetic Foot Images. **Journal of Diabetes Science and Technology**, [s. l.], v. 12, n. 1, 2018. Disponível em: <https://journals.sagepub.com/doi/10.1177/1932296817713761>.

7. ANEXO I – CERTIFICADO DE REGISTRO DE PROGRAMA DE COMPUTADOR.



REPÚBLICA FEDERATIVA DO BRASIL
MINISTÉRIO DA ECONOMIA
INSTITUTO NACIONAL DA PROPRIEDADE INDUSTRIAL
DIRETORIA DE PATENTES, PROGRAMAS DE COMPUTADOR E TOPOGRAFIAS DE CIRCUITOS INTEGRADOS

Certificado de Registro de Programa de Computador

Processo Nº: **BR512022001637-0**

O Instituto Nacional da Propriedade Industrial expede o presente certificado de registro de programa de computador, válido por 50 anos a partir de 1º de janeiro subsequente à data de 15/05/2022, em conformidade com o 52º, art. 2º da Lei 9.609, de 19 de Fevereiro de 1998.

Título: Claucia (Classificação de úlcera conforme inteligência artificial)

Data de publicação: 15/05/2022

Titular(es): FUNDAÇÃO UNIVERSIDADE DE BRASÍLIA

Autor(es): SUÉLIA DE SIQUEIRA RODRIGUES FLEURY ROSA; MARCELLA LEMOS BRETTAS CARNEIRO; THIAGO ALVES ESPINDOLA

Linguagem: PYTHON

Campo de aplicação: IF-10

Tipo de programa: IA-01

Algoritmo hash: SHA-512

Resumo digital hash:
CCF0A48A4E68EE37ADFED466FCB88B0FC507593979985B2E7364457CFA9D639BA4A05A1EF96224FDCEE75DA
49A62C2946306559FFE900448B381C4CBB3CDD92

Expedido em: 05/07/2022



Aprovado por:
Joelson Gomes Pequeno
Chefe Substituto da DIPTO - PORTARIA/INPI/DIRPA Nº 02, DE 10 DE FEVEREIRO DE 2021

15 de Novembro
REPÚBLICA FEDERATIVA DO BRASIL
de 1889