

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA BAIANO
TECNOLOGIA EM ANÁLISE E DESENVOLVIMENTO DE SISTEMAS

LUCAS FURTADO GÓES

A IMPLEMENTAÇÃO DE TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL
BASEADAS NO MÉTODO DE MONTE CARLO PARA ANÁLISE AUTOMATIZADA
E EXTRAÇÃO DIMENSIONAL DE FERIMENTOS EM IMAGENS DIGITAIS

CATU

2025

LUCAS FURTADO GÓES

**A IMPLEMENTAÇÃO DE TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL
BASEADAS NO MÉTODO DE MONTE CARLO PARA ANÁLISE AUTOMATIZADA
E EXTRAÇÃO DIMENSIONAL DE FERIMENTOS EM IMAGENS DIGITAIS**

Trabalho de Conclusão de Curso apresentado
ao Instituto Federal de Educação, Ciência e
Tecnologia Baiano como requisito parcial para
a obtenção do título de Tecnólogo em Análise
e Desenvolvimento de Sistemas.

Orientador: Dr. André Luiz Andrade Rezende
Co-orientador: Dr. Romero Mendes Freire de
Moura Júnior.

CATU

2025

Ficha catalográfica: Anderson Silva da Rocha - Bibliotecário - CRB 5/1508

G598i Góes, Lucas Furtado

A implementação de técnicas de inteligência artificial baseadas no método de Monte Carlo para análise automatizada e extração dimensional de ferimentos em imagens digitais / Lucas Furtado Góes. -- Catu, BA, 2025.

60 p.: il.

Trabalho de Conclusão de Curso (Tecnólogo em Análise e Desenvolvimento de Sistemas) - Instituto Federal de Educação, Ciência e Tecnologia Baiano - Campus Catu, 2025.

Orientador: Dr. André Luiz Andrade Rezende.

Coorientador: Dr. Romero Mendes Freire de Moura Júnior.

Bibliografia: p. 56 - 60

1. Inteligência artificial. 2. Ferimentos cutâneos.
3. Método de Monte Carlo. I. Rezende, André Luiz Andrade.
II. Moura Júnior, Romero Mendes Freire de. III. Título.

CDU: 004.8:61

LUCAS FURTADO GÓES

**A IMPLEMENTAÇÃO DE TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL
BASEADAS NO MÉTODO DE MONTE CARLO PARA ANÁLISE AUTOMATIZADA
E EXTRAÇÃO DIMENSIONAL DE FERIMENTOS EM IMAGENS DIGITAIS.**

Trabalho de Conclusão de Curso apresentado
ao Instituto Federal de Educação, Ciência e
Tecnologia como requisito parcial para
obtenção do Título de Tecnólogo em Análise e
Desenvolvimento de Sistemas.

APROVADO EM / /

BANCA EXAMINADORA

Título. Nome do Professor
Nome da Instituição

Título. Nome do Professor
Nome da Instituição

Título. Nome do Professor
Nome da Instituição

CATU
2025

AGRADECIMENTOS

Agradeço ao Centro de Supercomputação para Inovação Industrial do SENAI CIMATEC, pelo suporte, disponibilização de materiais, documentação para utilização e acesso aos recursos computacionais de alto desempenho, fornecendo sempre apoio técnico e investimento em pesquisas.

RESUMO

Ferimentos cutâneos representam um custo elevado para os sistemas públicos de saúde. Eles apresentam características e formatos distintos que dificultam a análise de suas dimensões durante o monitoramento. A Inteligência Artificial tem aberto novas perspectivas, produzindo modelos neurais que possibilitam a classificação, detecção e segmentação de imagens. Ademais, a estatística através do Método de Monte Carlo, traz uma metodologia que utiliza a randomização de pontos para descobrir a tendência de áreas irregulares. Este trabalho tem como objetivo desenvolver uma solução computacional baseada em inteligência artificial utilizando o Método de Monte Carlo para extração de dimensões de ferimentos. O desenvolvimento metodológico foi baseado nos ciclos PDCA, realizando o planejamento, execução, verificação e correção dos resultados a cada etapa do desenvolvimento. Os treinamentos e testes foram realizados nos ambientes *Google Colaboratory* e no supercomputador Ògún, disponibilizado pelo centro de supercomputação SENAI CIMATEC com conjuntos de dados públicos descritos durante o trabalho. Os métodos aplicados atingiram as metas estabelecidas nos ciclos PDCA, obtendo um valor de 92% de assertividade baseado nas métricas de *Jaccard* e o erro percentual entre o *Pixel Counting* das máscaras binárias e o Método de Monte Carlo foi inferior a 3%. Tais resultados foram satisfatórios indicando a importância de investimentos tecnológicos em soluções computacionais baseadas em IA na área médica.

Palavras-Chave: Ferimentos cutâneos; Inteligência Artificial; Método de Monte Carlo.

ABSTRACT

Skin wounds represent a high cost for public health systems. They exhibit distinct characteristics and shapes, making it difficult to analyze their dimensions during monitoring. Artificial Intelligence has opened new perspectives, producing neural models that enable the classification, detection, and segmentation of images. Furthermore, statistics through the Monte Carlo Method provide a methodology that uses point randomization to discover trends in irregular areas. This work aims to develop a computational solution based on artificial intelligence using the Monte Carlo Method to extract wound dimensions. The methodological development was based on PDCA cycles, performing planning, execution, verification, and correction of results at each development stage. Training and testing were conducted in Google Colaboratory environments and the Ògún supercomputer, provided by the SENAI CIMATEC supercomputing center, using public datasets described during the work. The applied methods achieved the goals established in the PDCA cycles, obtaining an accuracy rate of 92% based on Jaccard metrics, and the percentage error between Pixel Counting of binary masks and the Monte Carlo Method was less than 3%. These results were satisfactory, indicating the importance of technological investments in AI-based computational solutions in the medical field.

Keywords: Skin wounds; Artificial Intelligence; Monte Carlo simulations.

LISTA DE ABREVIATURAS E SIGLAS

IA	Inteligência Artificial
ML	Machine Learning
MIT	Massachusetts Institute of Technology
MOM	Modelo Oculto de Markov
UTI	Unidade de Terapia Intensiva
AUC	Area Under the Curve
OMS	Organização Mundial da Saúde
DL	Deep Learning
API	Application Programming Interface
LGPD	Lei Geral de Proteção de Dados
GDPR	General Data Protection Regulation
CNN	Convolutional Neural Network
SOBP	Spread out Bregg Peak
GPU	Graphics Processing Units
TPU	Tensor Processing Units
RGB	Red, Green, Blue
HPC	High Performance Computing
FTP	File Transfer Protocol
PIP	Package Installer for Python

SUMÁRIO

1	INTRODUÇÃO.....	8
1.1	Objetivos.....	10
2	REFERENCIAL TEÓRICO.....	11
2.1	A História da Inteligência Artificial.....	11
2.1.1	A Contribuição da Inteligência Artificial na Saúde.....	15
2.1.2	O uso responsável da Inteligência artificial.....	17
2.2	Ferimentos cutâneos.....	20
2.2.1	A importância da Inteligência Artificial para o tratamento de ferimentos.....	23
2.3	Método de Monte Carlo.....	24
3	METODOLOGIA.....	28
3.1	Planejamento.....	30
3.2	Execução.....	31
3.3	Checagem.....	32
3.4	Ação.....	33
3.5	Desenvolvimento metodológico.....	34
4	RESULTADOS E DISCUSSÕES.....	40
5	CONCLUSÃO.....	54
	REFERÊNCIAS.....	55

1 INTRODUÇÃO

Este Trabalho de Conclusão de Curso tem como tema, a implementação de técnicas de Inteligência Artificial baseadas no método de Monte Carlo¹ para análise de ferimentos cutâneos, a fim de proporcionar uma ferramenta que permita a análise e extração de dimensões de feridas, oferecendo apoio na avaliação e monitoramento destas lesões.

O presente trabalho surgiu como uma derivação da necessidade de automatizar o cálculo da área de ferimentos cutâneos, com o auxílio de IA para uma organização denominada Cicatribio², que representa uma convergência entre profissionais e estudantes de computação e química para produzir fármacos cicatrizantes.

A Cicatribio, através da sinergia entre profissionais da área química, explorou os compostos extraídos da mangaba para a produção de um fármaco, sob a coordenação dos Professores do IF Baiano Doutor Saulo Capim³, especialista na área de química medicinal, e a equipe de tecnologia, com Doutor André Rezende⁴, desenvolveram um *software*, resultando na concepção de um produto integrado que representa a comercialização conjunta de um fármaco, destinado à aplicação em feridas, e de um *software*, destinado a monitorar o processo de cicatrização dos ferimentos.

Ferimentos cutâneos representam um desafio significativo tanto no Brasil quanto no mundo, afetando milhões de pessoas anualmente. Globalmente, estima-se que os custos decorrentes da assistência de pacientes com feridas crônicas podem variar de 1% a 3% dos gastos relacionados à saúde pública (Phillips *et al.*, 2016). No Brasil, um estudo realizado em uma unidade de cuidados paliativos e prolongados apontou que os custos com materiais para curativos de lesões por pressão podem chegar a R\$ 445.664,38 por ano (Costa *et al.*, 2015). Essas lesões não apenas causam sofrimento físico, mas também geram um ônus financeiro considerável para os sistemas de saúde e para os pacientes afetados.

A falta de procedimentos e métodos ágeis e precisos para avaliar e monitorar o progresso de ferimentos cutâneos pode prolongar o tempo de recuperação, impactando negativamente na qualidade de vida de pacientes portadores de feridas crônicas. Técnicas de avaliação invasivas são mais comuns para análise de dimensão de ferimentos, a evolução tecnológica tem aberto novas perspectivas. Nesse contexto, soluções que integram tecnologia

¹ O método de Monte Carlo será abordado em maior detalhamento na Seção 2.3.

² A Cicatribio é a primeira startup do IF Baiano, voltada ao desenvolvimento de produtos sustentáveis a partir da biodiversidade brasileira. Mais informações em: <https://cicatribio.com.br>.

³ E-mail: saulo.capim@ifbaiano.edu.br Currículo Lattes: <http://lattes.cnpq.br/0034925996120563>

⁴ E-mail: andre.luiz.rezende@gmail.com Currículo Lattes <http://lattes.cnpq.br/7031235791316163>

e inteligência artificial para análise e avaliação de ferimentos cutâneos têm potencial de revolucionar cuidados médicos, agilizando processos e melhorando a precisão de análises sobre o tratamento.

A IA nos hospitais tem se revelado uma colaboradora essencial, ajudando profissionais de saúde na análise de doenças e exames. A IA desempenha uma função vital na gestão das informações dos pacientes, fornecendo análises detalhadas.

A aplicação de soluções computacionais que empregam algoritmos de inteligência artificial com uso do método de Monte Carlo oferece uma abordagem promissora para aprimorar a extração e análise de dimensões de feridas cutâneas. Essas tecnologias não só podem proporcionar uma avaliação ágil das feridas, mas também pode facilitar a comunicação entre profissionais de saúde, pacientes e cuidadores, resultando em uma prestação de cuidados mais eficaz.

Diante do impacto significativo dos ferimentos cutâneos na saúde pública e na qualidade de vida dos indivíduos, investir em soluções com uso de IA para extração e análise de feridas pode representar um passo crucial na melhoria dos cuidados de saúde, reduzindo custos e contribuindo para avaliações ágeis e eficazes dos ferimentos.

Sendo assim, o presente trabalho teve como questão problema: Como uma solução computacional com uso de técnicas de Inteligência Artificial baseadas no método de Monte Carlo pode extrair dimensões de ferimentos e fornecer análises através de imagens digitais?

Esse trabalho foi desenvolvido através de pesquisa e estudo quantitativo. Os dados foram obtidos por meio de suporte de livros digitais, artigos, sites, teses, trabalhos acadêmicos e plataformas de desenvolvimento.

1.1 Objetivos

Geral:

Desenvolver um modelo computacional com uso de técnicas de Inteligência Artificial baseadas no Método de Monte Carlo para extração dimensional de ferimentos.

Específicos:

- 1- Contextualizar a Inteligência Artificial.
- 2- Compreender a importância da Inteligência Artificial como ferramenta auxiliar para profissionais de saúde.
- 3- Analisar como a Inteligência Artificial pode contribuir para a análise e segmentação de ferimentos cutâneos.
- 4- Analisar como o Método de Monte Carlo pode extrair dimensões de figuras irregulares como ferimentos cutâneos.
- 5- Analisar métricas de avaliação para o modelo computacional.
- 6- Adquirir repositórios de dados para treinamento do modelo computacional.
- 7- Implementar algoritmos responsáveis pelo treinamento do modelo computacional.
- 8- Validar resultados obtidos pela implementação do modelo computacional.

2 REFERENCIAL TEÓRICO

2.1 A História da Inteligência Artificial

A Inteligência Artificial (IA), tem se tornado uma área de pesquisa cada vez mais proeminente, transformando a interação humana com a tecnologia e oferecendo uma ampla gama de aplicações em diversos setores. Assim, é imprescindível compreender e analisar as bases conceituais e teóricas dessas grandes áreas, bem como a contribuição de importantes figuras no desenvolvimento dessas áreas.


Segundo Sichman (2024), a IA é um campo multidisciplinar que se caracteriza pela aplicação de modelos, técnicas e tecnologias para resolver uma ampla gama de problemas complexos. Seus paradigmas principais incluem o simbólico, conexionista, evolutivo e probabilístico. No paradigma simbólico, o conhecimento é formalmente representado para inferência. O conexionista emprega redes neurais para aprendizado e generalização. O evolutivo utiliza métodos de otimização inspirados na evolução biológica. Enquanto isso, o paradigma probabilístico baseia-se em modelos estatísticos para inferência sobre distribuições condicionais de probabilidades. Esses paradigmas moldam abordagens diversas em IA capacitando-a a enfrentar desafios em variados domínios.

A IA, é um produto da segunda metade do século XX, onde embora o desejo de superar as limitações humanas por meio de artefatos externos ao corpo humano seja registrado desde a Antiguidade, a gênese da IA estar vinculada à Segunda Guerra Mundial e às experiências e tecnologias correlatas que esse evento trágico trouxe. O anseio de construir mecanismos capazes de agir de forma inteligente, simulando a inteligência humana, é um tema recorrente em diversas narrativas mitológicas, como o mito grego de Prometeu e o mito hebraico de Golem que refletem o desejo de criação, domínio da natureza e conservação e ampliação do potencial humano, que é inevitavelmente finito. (De Castro Barbosa, 2020).

Dentre os grandes influenciadores da computação moderna, destaca-se Alan Turing. O conceito de "Máquinas de Turing" desenvolvido em 1936 é considerado uma das contribuições mais significativas para a história da computação. Essas máquinas são modelos teóricos capazes de executar qualquer computação computável, representando assim a base matemática da computação moderna. A ideia de Turing, permitiu que ele estabelecesse os fundamentos da computação e um pouco depois da inteligência artificial, abrindo caminho para a criação de algoritmos e modelos que tentam simular o comportamento inteligente.

Os primórdios da Inteligência Artificial, são marcados por avanços significativos e contribuições de vários pesquisadores. O primeiro trabalho reconhecido como IA foi realizado por Warren McCulloch e Walter Pitts em 1943, que propuseram um modelo de neurônios artificiais baseado na fisiologia básica do cérebro, na lógica proposicional e na teoria da computação de Turing. Este trabalho pioneiro abriu caminho para o desenvolvimento do primeiro computador de rede neural, o Stochastic Neural Analog Reinforcement Calculator (SNARC), construído por Marvin Minsky e Dean Edmonds em 1950 (Russell; Norvig, 2013). A Figura 1 demonstra a representação visual do SNARC.

Figura 1 - Representação visual do SNARC



Fonte: (AKST, 2019).

Embora a Inteligência Artificial não fosse reconhecida como um campo de estudo na década de 1940, McCulloch e Walter Pitts realizaram um trabalho pioneiro que estabeleceu algumas das bases para a IA. Eles se inspiraram na anatomia do cérebro humano e nas teorias da computação da época, especialmente as ideias de Alan Turing, para desenvolver um modelo de neurônios artificiais. Este modelo viria a influenciar pesquisas futuras no campo da IA.

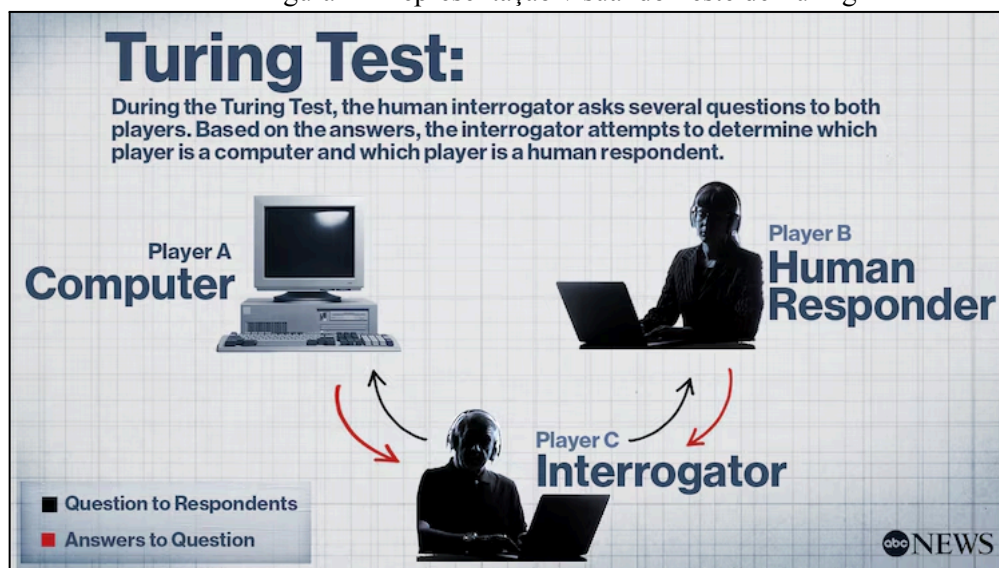
A visão mais influente nos primórdios da IA veio de Alan Turing, que já em 1947, estava dando palestras sobre o tema. Logo depois, em seu artigo de 1950, “*Computing Machinery and Intelligence*”, ele apresentou conceitos fundamentais como o teste de Turing, máquinas de aprendizado, algoritmos genéticos e aprendizagem por reforço. Sua proposta do “*Child Programme*” destacou a ideia de que seria mais eficaz desenvolver um programa que estimula a mente infantil, em vez da mente adulta. Esta visão de Turing continua a influenciar o campo da IA até hoje, reiterando a necessidade de uma abordagem responsável e ética à medida que continuamos a explorar e expandir as capacidades da IA.

A introdução do “Teste de Turing”, proposta em 1950, é uma das contribuições mais significativas para a inteligência artificial. Este teste tem como objetivo avaliar se uma

máquina pode exibir comportamento inteligente indistinguível de um ser humano, e para Turing, passar no teste seria evidência de uma forma de inteligência.

Desde então, o Teste de Turing tem sido amplamente utilizado como um padrão para avaliar a inteligência artificial e a capacidade das máquinas de imitar a inteligência humana. Ele se baseia na ideia de que, se uma máquina puder enganar um ser humano fazendo-o acreditar que está interagindo com outra pessoa, ela demonstraria uma forma de inteligência. O teste tem sido objeto de muitos debates e críticas, principalmente em relação à sua capacidade de realmente medir a inteligência. No entanto, continua sendo uma referência importante no campo da inteligência artificial e inspira novas pesquisas e desenvolvimentos na área. (Silva, 2022). A Figura 2 demonstra visualmente o Teste de Turing.

Figura 2 - Representação visual do Teste de Turing



Fonte: (Kekatos, 2023).

Embora o Teste de Turing seja uma referência importante, passar no teste não necessariamente implica em inteligência no sentido humano, a inteligência envolve mais do que apenas a capacidade de imitar um humano em uma conversa. Entretanto, o teste permitiu o desenvolvimento de técnicas influenciadas pelos conceitos de Turing como o aprendizado de máquina, que permite que as máquinas aprendam a partir de dados sem serem explicitamente programadas, os algoritmos genéticos, que são uma técnica de otimização inspirada na evolução natural, permitindo que os algoritmos passem por adaptações incrementais e a aprendizagem por reforço, um tipo de aprendizado onde um agente aprende a tomar decisões através de tentativa e erro.

O Teste de Turing pode ser limitado para medir a inteligência, já que formas de inteligência, como criatividade, emoções e compreensão contextual profunda, não são facilmente avaliadas por conversas textuais. Outra crítica é a natureza subjetiva do teste, pois determinar o sucesso pode depender da habilidade do juiz (avaliador das respostas) em discernir entre as respostas da máquina e as de um ser humano, levando a resultados inconsistentes. Ao longo dos anos, o teste inspirou novas abordagens na criação de sistemas de IA mais avançados. Mesmo não sendo uma medida definitiva de inteligência, o conceito do Teste de Turing desempenhou um papel crucial ao estabelecer um ponto de partida para refletir sobre a natureza da inteligência artificial e os desafios de criar máquinas verdadeiramente inteligentes (Lobo, 2017).

A IA foi registrada como um novo campo de conhecimento em 1956, após a conferência do Dartmouth College, nos EUA. Durante os anos de 1950 e 1960, houve avanços significativos na área, como a introdução do *Perceptron* por Frank Rosenblatt em 1957, que era uma rede neural de uma única camada capaz de classificar resultados. Em 1958, a linguagem de programação Lisp foi lançada, tornando-se padrão em sistemas de IA. Em 1959, o termo aprendizado de máquina foi usado referindo-se a um sistema que permite aos computadores aprenderem uma função sem serem explicitamente programados para isso. Em 1964, o público conheceu Eliza, o primeiro chatbot da história, desenvolvido por Joseph Weizenbaum no Instituto de Tecnologia de Massachusetts (MIT), que imitava uma psicanalista e conversava automaticamente com base em palavras-chave e estrutura sintática (De Castro Barbosa, 2020). A Figura 3 apresenta visualmente o chatbot Eliza.

Figura 3 - Representação visual do chatbot Eliza

```

Welcome to

EEEEEE LL      IIII ZZZZZZZ AAAAA
EE      LL      II   ZZ   AA  AA
EEEEEE LL      II   ZZ   AAAAAA
EE      LL      II   ZZ   AA  AA
EEEEEE LLLLLL IIII ZZZZZZZ AA  AA

ELIZA: Is something troubling you ?
YOU:   The weather
ELIZA: Tell me more about that.
YOU:   The weather is awful
ELIZA: Please go on.
YOU:   That's it
ELIZA: Does talking about this bother you ?
YOU:   It is
ELIZA: Tell me more about that.
YOU:   █

```

Fonte: (Blance, 2023).

Em 1969, Stanford lançou o DENDRAL, um programa pioneiro em IA para identificar estruturas moleculares usando espectrometria de massa. A equipe incluía Edward Feigenbaum, Bruce Buchanan e o laureado com o Nobel, Joshua Lederberg. O DENDRAL, com sua tomada de decisão autônoma, resolveu o desafio de inferir estruturas moleculares a partir de dados espectrométricos. Na década de 80, o primeiro sistema especialista comercialmente bem-sucedido, o R1, foi lançado pela DEC, desempenhando um papel crucial na definição de requisitos para novos sistemas de computador e gerando uma receita anual de cerca de 40 milhões de dólares até 1986. (Russell; Norvig, 2013).

Nos últimos anos, a IA passou por uma revolução metodológica. Na década de 1990, a IA começou a se integrar a outras disciplinas como teoria da informação e estatística. Abordagens baseadas em modelos ocultos de Markov (MOMs) dominaram o reconhecimento de fala, substituindo métodos intuitivos por teorias matemáticas rigorosas e treinamento com grandes conjuntos de dados. Essa evolução metodológica incluiu a aplicação de métodos científicos rigorosos, com hipóteses testadas empiricamente e resultados analisados estatisticamente, promovendo o uso de aplicações práticas e robustas em diversas áreas da IA (Russell; Norvig, 2013).

Portanto, para entender a IA e sua importância na qualidade de vida das pessoas, é fundamental conhecer sua origem e evolução. Compreender esses aspectos permite o desenvolvimento de estratégias, planos e ferramentas eficazes, assegurando uma vantagem no bem-estar desses indivíduos.

2.1.1 A Contribuição da Inteligência Artificial na Saúde

No setor da saúde, a IA tem desempenhado um papel transformador na maneira como os cuidados de saúde são prestados e gerenciados. Ela ajudou a superar alguns dos desafios mais prementes do setor, como a gestão eficiente dos dados dos pacientes e a redução dos erros médicos.

O uso da inteligência artificial, especialmente em hospitais, tem se revelado fundamental. Ela apoia profissionais de saúde na identificação de doenças, na interpretação de exames e na personalização de tratamentos. Além disso, melhora a eficiência operacional, diminuindo custos e erros médicos. Também é vital na gestão dos dados dos pacientes, proporcionando análises mais detalhadas e precisas. Dessa forma, a IA está revolucionando o atendimento médico, proporcionando maior precisão em diagnósticos, tratamentos efetivos e

um melhor controle de informações, tornando-se essencial para o futuro da medicina (CTC Tech, 2023).

O mapeamento patrocinado pela Bionexo, em parceria com a Associação Nacional de Hospitais Privados (Anahp), revelou que, apesar de 59% das instituições ainda não utilizarem a IA, mais da metade delas investiu em soluções baseadas nessa tecnologia nos últimos 2 anos. Além disso, 51% dessas instituições relataram resultados positivos com esses investimentos. A IA oferece oportunidades para otimizar diagnósticos, melhorar a eficiência operacional, personalizar tratamentos e aprimorar a experiência do paciente (Bionexo, 2023). Portanto, sua adoção é essencial para a evolução contínua da medicina e a entrega de cuidados de saúde eficazes e precisos.

Segundo Siddhartha Mukherjee (2017), em seu artigo *A.I. Versus M.D.: What Happens When Diagnosis Is Automated?*, publicado na revista The New Yorker, os avanços na IA estão transformando significativamente a prática médica, especialmente no campo da radiologia e do diagnóstico. O autor destaca que sistemas de aprendizado profundo têm sido desenvolvidos para diagnosticar doenças a partir de imagens médicas com precisão crescente, chegando, em alguns casos, a superar os diagnósticos realizados por médicos humanos.

A IA, oferece uma capacidade aumentada de processar grandes volumes de dados rapidamente, identificando padrões que podem passar despercebidos, o que pode levar a diagnósticos mais rápidos e precisos. Esses avanços têm o potencial de liberar os profissionais de saúde para se concentrarem em aspectos mais complexos do atendimento ao paciente, promovendo uma prática médica mais eficiente (Mukherjee, 2017).

Siddhartha Mukherjee (2017) relatou a experiência de Sebastian Thrun, cientista da computação da Universidade de Stanford, que desenvolveu um sistema de inteligência artificial baseado em uma rede neural treinada com 130 mil imagens de lesões de pele classificadas por dermatologistas. Em 2015, o sistema foi validado com 14 mil imagens diagnosticadas, alcançando uma precisão de 72%, superior aos 66% obtidos por especialistas. Posteriormente, a experiência foi ampliada para incluir 25 dermatologistas e 2 mil casos biopsiados, mantendo a IA sua superioridade em acurácia.

Fabrizzio *et al.* (2023) desenvolveram um aplicativo web preditivo baseado em um modelo de árvore de decisão, um método de aprendizado de máquina que realiza previsões a partir de decisões sequenciais, visando estimar o risco de internação em UTI de pacientes com COVID-19. O modelo alcançou uma Área Sob a Curva (AUC) de 0.668, métrica utilizada para avaliar sua capacidade de distinguir entre classes. Construído na linguagem de programação Python e implementado com a biblioteca *Streamlit*, o aplicativo demonstrou

eficácia e facilidade de uso para profissionais de saúde, apresentando bom potencial para aprimorar o gerenciamento e planejamento de cuidados intensivos durante a pandemia.

Fabrizio *et al.* (2023) em sua metodologia, coletaram dados de 547 pacientes diagnosticados com covid-19 e internados em cinco hospitais universitários brasileiros, entre os meses de abril e dezembro de 2021. Dentre as 23 variáveis associadas à Enfermagem de Precisão consideradas no estudo, incluíram-se informações sociodemográficas, biomarcadores clínicos, hábitos de vida e determinantes sociais e contextuais. O modelo de árvore de decisão foi escolhido como o mais eficaz, apresentando uma AUC de 0.668. Os dados foram divididos aleatoriamente para treinamento (75%) e teste (25%) do modelo, e técnicas de padronização e imputação foram aplicadas para lidar com valores ausentes e garantir a qualidade dos dados.

O desenvolvimento do Web App de Fabrizio *et al.* (2023) foi conduzido por uma equipe multidisciplinar composta por um engenheiro de *software* e duas enfermeiras especialistas em gestão em saúde, que colaboraram desde a coleta de dados até a implementação do aplicativo via *Streamlit* em *Python*.

Os resultados alcançados pelo estudo de Fabrizio *et al.* (2023) demonstraram a eficácia do Web App desenvolvido, o modelo apresentou uma capacidade satisfatória de predição. A interface do usuário permitiu uma visualização interativa das variáveis associadas à Enfermagem de Precisão, facilitando aos profissionais de saúde uma melhor compreensão das características dos pacientes estudados.

A contribuição da IA em diversas áreas da medicina, saúde e bem-estar das pessoas é notável. No entanto, à medida que essas aplicações avançam, torna-se fundamental adotar uma abordagem estratégica e responsável em seu uso. Isso envolve o desenvolvimento de algoritmos transparentes, a consideração de aspectos éticos e a busca pela mitigação de vieses, garantindo que os sistemas automatizados ofereçam suporte efetivo aos profissionais que irão usufruir dela, sem comprometer a privacidade ou segurança dos dados dos pacientes.

2.1.2 O uso responsável da Inteligência Artificial

A implementação da IA em setores críticos, como a saúde, deve apresentar um uso moderado e responsável. Embora a IA tenha o potencial de transformar a prestação de cuidados de saúde, tornando-a mais eficiente e precisa, é fundamental abordar sua utilização de maneira ética e responsável. Portanto, torna-se necessário uma abordagem cuidadosa para garantir a segurança do paciente e a confiança do público nesta tecnologia. Além disso, é

essencial a colaboração entre especialistas da área médica e profissionais de tecnologia para assegurar que os modelos computacionais sejam compatíveis com as necessidades reais dos pacientes e dos profissionais de saúde.

Se tratando do aumento da precisão diagnóstica e a facilitação da telemedicina várias contribuições substanciais foram trazidas. Segundo Monteiro (2023), tecnologias baseadas em IA permitem diagnósticos mais rápidos e precisos, além de possibilitar o monitoramento remoto de pacientes, o que contribui para uma gestão mais eficaz das condições de saúde. Contudo, há desafios a serem superados, como a dependência excessiva da tecnologia, que pode reduzir as habilidades clínicas dos profissionais, e preocupações com a segurança dos dados. Portanto, é crucial o treinamento adequado e a criação de regulamentações claras para equilibrar os benefícios da tecnologia com a prática médica tradicional (Monteiro, 2023).

Embora a eficácia dos sistemas de inteligência artificial no diagnóstico seja amplamente documentada, sua eficiência total depende de vários fatores, como a qualidade dos dados de treinamento, a integração com os sistemas de saúde existentes e a aceitação por parte dos profissionais médicos (Mukherjee, 2017). Além disso, é essencial considerar as questões éticas e a privacidade dos dados dos pacientes. A inteligência artificial deve ser vista como uma ferramenta complementar, e não como uma substituta dos médicos, para maximizar seu impacto positivo na prática clínica. Dessa forma, sua integração bem-sucedida na medicina exige uma abordagem cuidadosa e ética, que envolva treinamento adequado e infraestrutura robusta (Mukherjee, 2017).

Eduardo Salles em seu artigo “*Como utilizar a inteligência artificial na prática da medicina*” (Salles, 2024), destaca que a IA tem o potencial de melhorar significativamente a eficiência e a precisão dos cuidados de saúde. No entanto, é crucial garantir que essas ferramentas sejam usadas de maneira responsável e que os profissionais de saúde mantenham a responsabilidade final sobre as decisões. A IA pode ser uma ferramenta valiosa para pesquisa, redação de documentos e análise de dados, mas deve ser usada com a devida cautela para evitar erros ou mal-entendidos. A adoção ética e responsável da IA na medicina não só garantirá a segurança do paciente, mas também ajudará a ganhar a confiança do público nesta tecnologia emergente (Salles, 2024).

O uso estratégico da IA na área da saúde envolve aproveitar suas capacidades para melhorar o desempenho dos processos clínicos e a tomada de decisão médica. Isso implica integrar tecnologias em diversos aspectos das operações hospitalares, clínicas e de pesquisa para impulsionar eficiência, e qualidade no atendimento. Esse uso estratégico requer uma análise cuidadosa das necessidades de saúde, identificando oportunidades, onde a IA pode

agregar valor, e reimaginando protocolos e procedimentos para aproveitar todo o seu potencial.

O desafio regulatório na inteligência artificial, em saúde, reside na distinção entre a IA tradicional, em uso desde os anos 1950, e as técnicas mais recentes de *machine learning* (ML) e *deep learning* (DL), que apresentam complexidades únicas. O *machine learning* permite que computadores aprendam automaticamente sem programação explícita, enquanto o *deep learning*, um subtipo, utiliza redes neurais artificiais inspiradas no sistema nervoso central para aprender relações complexas. Esses algoritmos, ao lidar com dados clínicos heterogêneos, como registros médicos e imagens, desafiam a regulação tradicional, sendo em constante evolução.

A Organização Mundial da Saúde (OMS) propõe seis princípios-chave para regulamentar a IA em saúde: autonomia, não-maleficência/beneficência, transparência, responsabilidade, equidade e responsividade/sustentabilidade. Esses princípios, interligados e sem hierarquia, buscam orientar a regulamentação, reconhecendo a necessidade de instrumentalizá-los conjuntamente diante do desafio dinâmico de regular tecnologias em constante aprimoramento (Dourado; Aith, 2022).

De acordo com Lei Geral da Proteção de Dados - Lei Nº 13.709, no Artº. 20, parágrafos 1 e 2, relata que:

Artº. 20. O titular dos dados tem direito a solicitar a revisão de decisões tomadas unicamente com base em tratamento automatizado de dados pessoais que afetem seus interesses, incluídas as decisões destinadas a definir o seu perfil pessoal, profissional, de consumo e de crédito ou os aspectos de sua personalidade. § 1º O controlador deverá fornecer, sempre que solicitadas, informações claras e adequadas a respeito dos critérios e dos procedimentos utilizados para a decisão automatizada, observados os segredos comercial e industrial. § 2º Em caso de não oferecimento de informações de que trata o § 1º deste artigo baseado na observância de segredo comercial e industrial, a autoridade nacional poderá realizar auditoria para verificação de aspectos discriminatórios em tratamento automatizado de dados pessoais (Planalto, 2018).

A Lei Geral de Proteção de Dados (LGPD), promulgada em agosto de 2018 e em vigor desde setembro de 2020 (com as sanções administrativas iniciando em agosto de 2021), é fundamental para a privacidade de dados pessoais. Embora ela não aborda explicitamente a regulamentação da inteligência artificial, ela incorpora elementos do Regulamento Geral sobre a Proteção de Dados da União Europeia (GDPR). Essa legislação estabelece princípios e bases legais para o tratamento de dados, promovendo mais transparência e controle aos titulares.

A LGPD, introduz no direito brasileiro o direito à explicação e à revisão de decisões automatizadas, destacando o artº. 20, que concede ao titular o direito de solicitar a revisão de decisões baseadas em tratamento automatizado. Notavelmente, a legislação brasileira não inclui o direito de não se sujeitar a decisões exclusivamente automatizadas, diferenciando-se da abordagem do GDPR. Embora o direito à explicação não seja mencionado textualmente, a LGPD assegura a todos os afetados por decisões automatizadas o direito a obter informações claras sobre os critérios e procedimentos utilizados, expressando o princípio da transparência de maneira alinhada ao GDPR e seguindo os princípios destacados pela OMS, mas com suas peculiaridades.

Segundo Carvalho et al. (2021), o rápido crescimento dos dados, caracterizado pelos três V's: Volume, Variedade e Velocidade, exige algoritmos de IA cada vez mais sofisticados para processar e analisar esses dados de maneira eficiente. Além disso, a necessidade de conformidade com a LGPD exige que as organizações sejam transparentes sobre como coletam, usam e armazenam os dados pessoais dos usuários, o que pode ser um desafio significativo para as organizações que dependem de algoritmos de IA para suas operações. Portanto, é crucial que as organizações adotem uma abordagem responsável ao uso da IA garantindo que essas tecnologias sejam usadas de maneira ética e justa (Carvalho et al, 2021).

O manuseio da IA deve ser de maneira responsável, conforme previsto em regulamentações como a LGPD. Uma das áreas que se beneficia de inovações é o tratamento de ferimentos cutâneos. Logo, é importante investigar eticamente sobre soluções que podem contribuir para esta determinada área da saúde.

2.2 Ferimentos cutâneos


A pele é um dos órgãos mais importantes do corpo, ela desempenha diversas funções essenciais como proteção, secreção, excreção, absorção, metabolismo, termorregulação, sensação e imagem corporal. A pele é composta por 2 camadas: epiderme e derme (Sanar, 2020).

A epiderme é uma camada fina e avascular que se regenera em 4 a 6 semanas, sua principal função é servir como barreira contra agentes externos. A derme fornece suporte à epiderme, caracteriza-se por fibroblastos, colágeno e fibras elásticas, que promovem resistência e elasticidade (Sanar, 2020).

A epiderme evita a penetração de substâncias prejudiciais. No entanto, quando a pele se desidrata, as células na camada superficial encolhem, resultando na abertura da epiderme e

na ruptura da barreira cutânea. Isso cria aberturas, onde substâncias indesejadas podem penetrar no corpo. Além disso, a capacidade da pele de reter umidade é comprometida, aumentando o risco de ferimentos cutâneos (Langøen e Bianchi, 2013). A Figura 4 demonstra visualmente as camadas da pele.

Figura 4 - Representação das camadas da pele



Fonte: (Carmo; Zehra, 2023).

De acordo com o Corpo de Bombeiros Militar do Paraná (2018):

Ferimento é qualquer lesão ou perturbação produzida em qualquer tecido por um agente externo, físico ou químico. Os agentes capazes de produzir um ferimento podem ser físicos (mecânico, elétrico, irradiante e térmico) e químicos (ácidos ou álcalis). (Corpo de Bombeiros Militar do Paraná, 2018, p.1)

Os ferimentos cutâneos podem surgir por diversas causas distintas. Entre as causas cirúrgicas estão as provocadas intencionalmente durante procedimentos como incisões, sem perda significativa de tecido, excisões que removem áreas da pele, e punções resultantes de procedimentos terapêuticos ou diagnósticos. Os ferimentos traumáticos são frequentemente causados por agentes mecânicos, químicos (como substâncias irritantes) e físicos (como temperaturas extremas ou radiação). Ferimentos ulcerativos, como úlceras de pressão e diabéticas, resultam de traumatismos ou doenças que comprometem o suprimento sanguíneo

da pele (Sanar, 2020). A Figura 5 apresenta visualmente um ferimento cutâneo localizado na região da perna de um paciente.

Figura 5 - Representação visual de ferimento cutâneo



Fonte: (Faleiros, 2018).

Os ferimentos podem ser classificados quanto à duração. Os ferimentos podem ser agudos, recentemente ocorridos, ou crônicos, caracterizados por um tempo prolongado de cicatrização que excede o esperado, frequentemente sem a regeneração esperada dentro do período normal. Essas categorizações ajudam a compreender a diversidade e a complexidade dos ferimentos cutâneos e suas implicações na prática clínica (Sanar, 2020).

Conforme Alves *et al.* (2015), uma das abordagens para a avaliação dos ferimentos cutâneos se baseia em seus tamanhos, bordas e profundidade, dividindo-os em categorias que variam desde lesões superficiais até aquelas que acometem camadas mais profundas da pele e estruturas subjacentes. Neste contexto, a classificação de feridas proposta por Bates-Jensen é uma estrutura usada na avaliação e classificação de feridas que auxilia os profissionais de saúde a entenderem melhor a extensão e a gravidade das lesões cutâneas.

Segundo Alves *et al.* (2015), a classificação e avaliação de ferimentos cutâneos é bastante útil na prática clínica, pois fornece uma maneira padronizada de descrever e documentar diferentes tipos de feridas.

A classificação dos ferimentos cutâneos é, portanto, um aspecto fundamental no contexto da medicina, e a aplicação de métodos computacionais, aliados à inteligência artificial, pode revolucionar a maneira como essas lesões são avaliadas e tratadas, proporcionando uma abordagem mais precisa e eficiente para a prática clínica.

2.2.1 A importância da Inteligência Artificial para o tratamento de ferimentos

No contexto da medicina moderna, avanços tecnológicos têm permitido o uso de sistemas inteligentes para auxiliar na classificação automatizada de ferimentos cutâneos. Métodos baseados em inteligência artificial têm sido empregados para analisar imagens de feridas, oferecendo uma abordagem objetiva e precisa para a classificação. Essas técnicas não apenas categorizam os ferimentos, mas também podem estimar sua extensão, auxiliando na determinação do plano de tratamento mais apropriado (Smaniotto et al, 2012).

A área de estudo concernente à análise e diagnóstico de lesões de pele tem sido objeto de pesquisa e desenvolvimento em diversos estudos recentes. Dentre eles, merecem destaque alguns trabalhos que exploraram abordagens inovadoras e tecnologias emergentes para a segmentação e caracterização precisa de lesões cutâneas.

O *software* desenvolvido pelo presente trabalho, possuiu a proposta de automatizar a extração de dimensões de ferimentos cutâneos através de imagens com auxílio de inteligência artificial. O modelo computacional pode ser utilizado em diferentes plataformas e disponível através de interface de programação de aplicações (API), permitindo integração com diferentes interfaces de usuário.

Em sua monografia intitulada "Segmentação Semântica de Lesões de Pele utilizando Redes Neurais Convolucionais" (Ferreira, 2018), Bruno Eduardo Silva Ferreira propôs uma abordagem utilizando Redes Neurais Convolucionais (CNNs) para a segmentação precisa de lesões de pele. Sua pesquisa na Universidade Federal do Maranhão ofereceu contribuições significativas no desenvolvimento de métodos de segmentação semântica, proporcionando uma análise detalhada e precisa das lesões, com potenciais implicações na precisão do diagnóstico.

A pesquisa conduzida por Ferreira (2018), se concentrou na aplicação de Redes Neurais Convolucionais (CNNs) para realizar a segmentação precisa de lesões de pele, proporcionando análises minuciosas para aprimorar a precisão do diagnóstico. Por outro lado, o escopo do presente trabalho é direcionado à automação do cálculo da extensão da dimensão de ferimentos cutâneos com auxílio de inteligência artificial por meio da análise de imagens. O propósito é desenvolver uma abordagem que viabilize uma análise de dimensão eficiente das feridas, possibilitando a identificação e mensuração rápida das áreas afetadas.

Além disso, os trabalhos conduzidos por Steppan e Hanke (2021) e Jaganathan *et al.* (2023), intitulados "*Analysis of Skin Lesion Images with Deep Learning*" e "*Validating Wound Severity Assessment via Region-Anchored Convolutional Neural Network Model for Mobile*

Image-Based Size and Tissue Classification", respectivamente, destacaram-se pela aplicação de Redes Neurais Convolucionais ancoradas em regiões para a avaliação de gravidade de feridas. Suas contribuições foram relevantes na validação de métodos de avaliação de feridas com base em imagens fornecidas por dispositivos móveis, oferecendo um modelo robusto para a classificação de tamanho e tipo de tecido.

Embora siga na mesma linha do trabalho de Jaganathan *et al.* (2023), este trabalho se diferencia ao proporcionar não apenas a medição automatizada dos ferimentos cutâneos, mas também a possibilidade de acompanhamento contínuo com baixo custo e sem necessidade de equipamentos de *hardware* específicos. Utilizando um modelo neural integrado a uma interface de programação de aplicações (API), é possível extrair dimensões e monitorar a evolução das feridas. Esta abordagem permite acessibilidade para profissionais de saúde e pacientes, garantindo que o tratamento das feridas possa ser acompanhado em tempo real, melhorando a gestão dos cuidados médicos.

Os estudos apresentados demonstram a crescente aplicação de técnicas e tecnologias avançadas, como Inteligência Artificial, Redes Neurais Convolucionais e automação por meio de aplicativos digitais, na análise de lesões de pele. A sinergia entre esses trabalhos, destaca o avanço contínuo na busca por métodos precisos e eficientes de extração de dimensões de ferimentos cutâneos, indicando um caminho promissor para a melhoria da prática clínica e da saúde dermatológica. Entre tais métodos, vale a pena destacar o papel da estatística para uma abordagem planimétrica das dimensões dessas feridas.

2.3 Método de Monte Carlo

A estatística desempenha um papel imprescindível a respeito do cálculo de áreas, especialmente quando se trata de extração de superfícies e dimensões complexas ou realizar análises em amostras de dados espaciais. Com o uso de técnicas estatísticas, através de métodos de amostragem aleatória, pode se tornar possível calcular a área de figuras irregulares ou realizar estimativas precisas em situações onde o cálculo direto seria inviável ou muito trabalhoso.

O Método de Monte Carlo é uma técnica matemática frequentemente utilizada em diversos segmentos da ciência nos dias de hoje. O método permite a resolução de problemas através de simulações de processos randômicos. O método surgiu em meados da Segunda Guerra Mundial durante o Projeto *Manhattan* e por ter embasamento em eventos randômicos e por ser normalmente vinculado a jogos de azar, Ulam e Von Neumann denominaram “Monte


Carlo”, fazendo referência à famosa cidade de Mônaco conhecida mundialmente como a capital dos jogos de azar (Yoriyaz, 2024).

Segundo Yoriyaz (2024), o Método de Monte Carlo se define como um método estatístico que através da utilização de uma cadeia de números aleatórios torna possível realizar simulações para analisar e resolver um problema. Este método é de suma importância para o presente trabalho devido a possibilidade de gerar análises quantitativas de dados como dimensões de figuras irregulares.

Salinas Domjan *et al.* (2022), relataram uma metodologia para desenvolver um modelo computacional através das simulações de Monte Carlo implementada ao código FLUKA a fim de descrever os processos físicos na irradiação da terapia de prótons. Ele utilizou dados experimentais para comparação e validação dos dados e descreveu todo o procedimento de geração do *Spread out Bragg Peak* (SOBP), técnica que utiliza feixes de prótons de diferentes energias para criar uma distribuição de dose uniforme ao longo da profundidade do alvo, para aplicações em irradiação intracraniana.

Os resultados da metodologia proposta por Salinas Domjan *et al.* (2022), através da comparação de dados experimentais e o processo de formação do *Spread Out Bragg Peak* (SOBP), foram bem-sucedidos alcançando os objetivos propostos. Houve Diferenças variando de 0,035 cm a 0,05 cm entre os valores obtidos por simulação e os dados experimentais, sendo que o modelo permite uma tolerância de variação de até 0,1 cm para cada pixel na representação gráfica. Em resumo, a metodologia através das simulações de Monte Carlo demonstrou ser promissora para planejamento e aplicação de irradiações representativas de terapia de prótons intracranianas.

O método de Monte Carlo é amplamente utilizado para estimativas numéricas, incluindo o cálculo de áreas com contornos irregulares. A técnica se baseia na geração de pontos aleatórios dentro de uma região conhecida, avaliando a proporção que cai na área de interesse. A Figura 6 ilustra a aplicação do Método de Monte Carlo por meio da geração de pontos distribuídos aleatoriamente dentro de um quadrado de lado unitário. Os pontos vermelhos representam aqueles que estão localizados dentro de um quarto de círculo inserido no canto inferior esquerdo de um quadrado com lados iguais. Já os pontos azuis correspondem aos que ficam fora dessa região circular, mas ainda dentro do quadrado. Como a área do quarto de círculo é uma fração conhecida da área total do quadrado, a proporção de pontos vermelhos em relação ao total de pontos gerados permite estimar essa fração. Multiplicando essa razão por quatro, obtém-se uma aproximação do valor de π .

Figura 6 - Simulação de Monte Carlo para Aproximação de π em $\frac{1}{4}$ de Círculo

Fonte: (Marinho, 2021).

No trabalho de mestrado de Ricardo Cordeiro de Souza (2018), o método de Monte Carlo foi um dos métodos adotados para extração de dimensões de feridas. Foram realizados enquadramentos manuais em imagens de ferimentos cutâneos, através de *software* desenvolvido pelo autor, para delimitar a região do ferimento. Após a delimitação, foram gerados pontos aleatórios dentro do limite e cada ponto fez parte de uma categoria. A área total da figura foi definida sendo igual à área do retângulo multiplicada pelo rácio entre o número de pontos dentro e o número total de pontos. A destreza do método depende do número total de pontos gerados.

Os resultados do mestrado de Souza (2018) destacaram que o Método de Monte Carlo se trata de um método que sua precisão pode variar de acordo com o número total de pontos aleatórios gerados, aumentando assim o tempo total das iterações. Entretanto, ele não levou em conta o tamanho das imagens e o auxílio de tecnologias mais aprofundadas em visão computacional e inteligência artificial que poderiam ser eficientes na otimização da delimitação e segmentação dessas figuras, assim podendo tornar o método mais rápido e preciso.

Portanto, o Método de Monte Carlo pode ser uma metodologia útil e promissora para o cálculo de dimensões de feridas. Como demonstrado no trabalho de Salinas Domjan *et al.* (2022), a aplicação desse método em simulações físicas, como na terapia de prótons, obteve resultados experimentais de alta precisão. Da mesma forma, o estudo de Souza (2018) evidenciou o uso do método na extração de dimensões de feridas, apesar de apontar limitações relacionadas ao número de pontos gerados e ao tempo de iteração. No entanto, com o uso de

tecnologias mais avançadas, como visão computacional e inteligência artificial, há potencial para melhorar ainda mais a precisão e eficiência do método Monte Carlo, reforçando seu valor para aplicações em áreas da saúde.

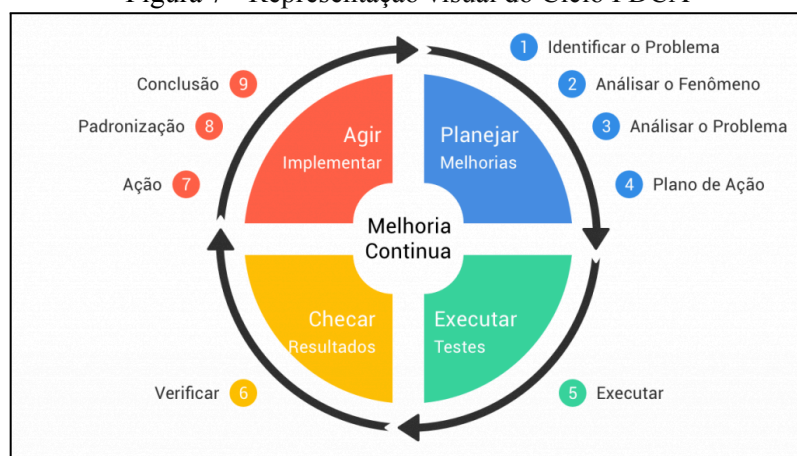
3 METODOLOGIA

A elaboração deste trabalho utilizou como base metodologia ágil, tal como o método PDCA, que se destaca como uma ferramenta de gestão de projetos para melhorar processos e solução de programas e o método de Monte Carlo, que utiliza procedimentos através de simulações randômicas para extrair dados.

O PDCA, conhecido também como método de melhorias, é dividido em 4 partes, são elas: Planejar (*Plan*), Fazer (*DO*), Checar (*Check*) e Agir (*Act*). O método é fundamentado em conceitos da administração clássica podendo ser implementado de forma sequencial por meio de módulos, sendo que sua fase inicial deve ser a estruturação do trabalho que logo após torna-se mensurável e repetitivo, formando ciclos (Andrade, 2003).

A etapa de planejamento (*Plan*) visa definir as metas e a metodologia adequada para o desenvolvimento do projeto. A fase de execução (*DO*) são feitas as atividades conforme estabelecidas pela etapa anterior e é nela que acontece a coleta de dados para que sejam analisados na etapa seguinte. A etapa de checagem (*Check*) realiza análises comparativas dos resultados obtidos com as metas realizadas a fim de identificar as possibilidades de melhorias ou aperfeiçoamento. Na fase de ação (*Action*) ocorrem as atuações de correção ou aperfeiçoamento em função dos resultados obtidos, sendo eles positivos ou negativos. Ao finalizar a última etapa, o ciclo se reinicia a fim de obter novos resultados, promovendo constantes evoluções no trabalho (Ruivo, 2024). A Figura 7 apresenta visualmente as etapas do ciclo PDCA.

Figura 7 - Representação visual do Ciclo PDCA



Fonte: (Tecnologia E Produto, 2020).

As atividades desenvolvidas neste Trabalho de Conclusão de Curso foram organizadas em etapas conforme o ciclo PDCA. Esta metodologia foi essencial para que as metas e objetivos do trabalho fossem atingidas e aperfeiçoadas. No Quadro 1 segue a estrutura dos ciclos abordados no presente trabalho:

Quadro 1 - Distribuição de atividades do ciclo PDCA

Ciclo 1	
Planejar	Construir um conjunto de dados com número de imagens de ferimentos cutâneos iguais ou superiores a 1.000.
	Os valores das variáveis de desempenho do modelo devem ser iguais ou superiores a 90%.
	O erro percentual da média das dimensões extraídas do método de Monte Carlo em relação ao <i>Pixel counting</i> das máscaras binárias deve ser inferior a 3%.
Fazer	Pesquisar por repositórios públicos de imagens de ferimentos.
	Pesquisar por ambientes de treinamento que atendam aos critérios pré-estabelecidos.
	Configurar ambiente de execução.
	Executar treinamento do modelo.
	Extrair dimensões das máscaras binárias geradas pelo modelo.
Checar	Validar implementações realizadas.
Agir	O conjunto de dados igual ou superior a 1.000 imagens de ferimentos foi construído?
	Os valores das variáveis de desempenho do modelo foram iguais ou superiores a 90%?
	O erro percentual da média das dimensões extraídas do método de Monte Carlo em relação ao <i>Pixel counting</i> das máscaras binárias foi inferior a 3%?

Ciclo 2	
Planejar	Ampliar conjunto de dados para número de imagens de ferimentos cutâneos superiores a 40.000.
	Os valores das variáveis de desempenho do modelo devem ser iguais ou superiores a 90%.
	O erro percentual da média das dimensões extraídas do método de Monte Carlo em relação ao <i>Pixel counting</i> das máscaras binárias deve ser inferior a 3%.
Fazer	Aplicar técnica de aumento de dados.
	Executar treinamento do modelo.
	Extrair dimensões das máscaras binárias geradas pelo modelo.
Checar	Validar implementações realizadas.
Agir	O conjunto de dados superior a 40.000 imagens de ferimentos foi construído?
	Os valores das variáveis de desempenho do modelo foram iguais ou superiores a 90%?
	O erro percentual da média das dimensões extraídas do método de Monte Carlo em relação ao <i>Pixel counting</i> das máscaras binárias foi inferior a 3%?

Fonte: Elaborado pelo autor.

3.1 Planejamento

O primeiro ciclo tomou como ponto de partida a consolidação de bases teóricas visando proporcionar maior entendimento sobre o problema em questão e realizar análises de trabalhos correlatos que abordam soluções semelhantes ao tema do trabalho de conclusão de curso.

Após a maturação das bases teóricas, estabeleceram-se 3 metas: construção de um conjunto de dados com mínimo de 1.000 imagens de ferimentos cutâneos, atingir métricas

acima de 90% com base no coeficiente de assertividade e perda de Jaccard e obter um erro percentual menor que 3% dos valores gerados pelo método de Monte Carlo em relação ao *Pixel counting* das máscaras binárias dos ferimentos geradas pelo modelo treinado.

O coeficiente de assertividade de Jaccard é responsável por medir a sobreposição entre duas áreas. Seu principal uso está em tarefas de segmentação de imagens ou classificação multiclasse, ele varia de 0 a 1, onde o valor 1 indica a correspondência exata, isso significa que o modelo está coincidindo com a verdade real e 0 indica que não há sobreposição.

A função de perda do coeficiente de Jaccard é a negativa do coeficiente de assertividade, ela mostra o quanto o modelo está distante da correspondência ideal. Ela varia de 0 a -1, onde o valor -1 desta métrica equivale para a correspondência perfeita do valor real.

O *Pixel counting* é utilizado para medir a quantidade de pixels pertencentes a região de interesse depois da segmentação gerada pelo modelo. os pixels são representados por 0 (fundo) e 1 (lesão), a contagem dos pixels com valor 1 permite estimar características da área da lesão. Essa abordagem é simples e eficiente para análise quantitativa em imagens digitais.

O método de Monte Carlo foi utilizado para gerar pontos aleatórios dentro da máscara binária e logo após, é medida a proporção de pontos que caíram dentro da região irregular em relação ao número total de pontos gerados. Ao final, é multiplicada a área total da máscara binária pela proporção de pontos que caíram dentro da região de interesse. Desta maneira, foi possível chegar a uma medida aproximada da área do ferimento.

Para o segundo ciclo, visou-se o aumento do conjunto de dados. Foi estabelecida a meta de alcançar 40.000 imagens de ferimentos cutâneos objetivando o aperfeiçoamento do desempenho do modelo. Através de uma maior quantidade de dados, a inteligência artificial consegue generalizar melhor devido à maior variação de cenários, padrões e exceções.

3.2 Execução

Na etapa de execução, foram feitas pesquisas em repositórios públicos a fim de encontrar um conjunto de dados com um número relevante de imagens. Dessa maneira a primeira meta estabelecida poderia ser concluída.

Para atender a segunda meta do planejamento, foi necessário a realização da escolha de um ambiente de execução, configuração do ambiente e a execução do treinamento da inteligência artificial.

O ambiente de execução escolhido foi o *Google Colaboratory*. O *Google Colaboratory*, apelidado de *Colab* pela comunidade de desenvolvedores, é um ambiente de

notebook baseado em nuvem oferecido gratuitamente pelo Google. Nele, é possível escrever e executar código *Python* diretamente no navegador, sem necessidade de instalação. O *Colab* proporciona acesso a recursos computacionais, como GPUs e TPUs, permitindo treinar e executar modelos de aprendizado de máquina de maneira veloz.

Para configurar o ambiente no *Google Colab*, foi necessário acessar o conjunto de dados no ambiente de desenvolvimento e trocar o ambiente de execução da plataforma. Foi escolhido o ambiente de execução com GPU dedicada para que haja uma maior velocidade durante o treinamento.

Em busca de atingir a terceira meta, a extração dos valores das dimensões dos ferimentos foi feita passando como parâmetro máscaras binárias dos ferimentos para as funções escritas nos algoritmos de *Pixel Counting* e o método de Monte Carlo. Logo após a extração das dimensões, foi realizado o cálculo comparativo da variação entre os valores gerados entre os algoritmos.

Para atingir a primeira meta estabelecida no segundo ciclo, o uso de técnicas de aumento de dados foram aplicadas. O *Data Augmentation* foi o conjunto de técnicas usado visando melhorar a qualidade do conjunto para treinar o modelo. Foram aplicadas transformações às imagens originais, gerando novas amostras de treinamento.

Por fim, para atingir a segunda e a terceira meta estabelecida no segundo ciclo, o conjunto de dados foi modificado e realizou-se um novo treinamento do modelo com as alterações realizadas. Após o treinamento foi realizado o cálculo comparativo da variação entre os valores obtidos pelo método de Monte Carlo e o *Pixel counting* das máscaras binárias geradas pelo modelo.

3.3 Checagem

A checagem das ações tomadas a fim de resolver a primeira meta do primeiro ciclo foi feita. Para este trabalho foi utilizada a base de dados de treinamento disponibilizada publicamente no repositório *uwm-bigdata/wound-segmentation* da *University of Wisconsin-Milwaukee* na plataforma *Github*, construída pelo laboratório e clínica de colaboração, *Advancing the Zenith of Healthcare (AZH) Wound and Vascular Center*, Milwaukee, WI, dos Estados Unidos. No conjunto de dados escolhido foram contabilizadas 1.210 imagens de úlceras e máscaras binárias de 889 pacientes, cumprindo então a meta estabelecida.

Ao analisar os resultados do treinamento realizado, foi possível observar que a meta de atingir métricas iguais ou maiores que 90% do coeficiente de Jaccard não foram alcançadas, assim não cumprindo com o segundo objetivo estabelecido no primeiro ciclo.

Em análise aos valores extraídos pelos algoritmos responsáveis por calcular as dimensões dos ferimentos, foi possível atingir a meta estabelecida, sendo o erro percentual da média dos valores obtidos pelo método de Monte Carlo menor que 3% em relação ao *Pixel Counting*.

Em progresso às análises feitas, no segundo ciclo, a primeira meta que visava atingir um número superior a 40.000 imagens de ferimentos cutâneos foi atingida através das técnicas de aumento de dados implementadas na etapa de execução.

Os valores resultantes do treinamento da etapa de execução com um novo conjunto de dados melhorou significativamente o desempenho do modelo, alcançando a segunda meta e aprimorando a terceira meta estabelecida no segundo ciclo na metodologia.

3.4 Ação

No primeiro ciclo, foram feitas duas perguntas para obter respostas que orientarão as ações a serem tomadas, caso as metas definidas no planejamento não sejam alcançadas. As perguntas foram: O conjunto de dados igual ou superior a 1.000 imagens de ferimentos foi construído?; Os valores das variáveis de desempenho do modelo foram iguais ou superiores a 90%?; O erro percentual da média das dimensões extraídas do método de Monte Carlo em relação ao *Pixel counting* das máscaras binárias foi inferior a 3%?

O conjunto de dados obtido pelo repositório *uwm-bigdata/wound-segmentation* da *University of Wisconsin-Milwaukee* cumpriu com a primeira meta estabelecida no planejamento. Contudo, a quantidade de dados não foi suficiente para que os números dos coeficientes de Jaccard atingissem o mínimo estabelecido.

Em vista da não conformidade com as metas estabelecidas, houve uma revisão do planejamento para o segundo ciclo. As perguntas no segundo ciclo foram alteradas para: O conjunto de dados superior a 40.000 imagens de ferimentos foi construído?; Os valores das variáveis de desempenho do modelo foram iguais ou superiores a 90%?; O erro percentual da média das dimensões extraídas do método de Monte Carlo em relação ao *Pixel counting* das máscaras binárias foi inferior a 3%?

Através das técnicas de aumento de dados, o conjunto de dados aumentou resultando em uma quantidade adequada de imagens. Com um número maior de dados, o modelo atingiu

desempenho melhor cumprindo com todas as metas estabelecidas no ciclo 2, tornando-se desnecessário o desenvolvimento de um novo ciclo.

3.5 Desenvolvimento metodológico

A construção do conjunto de dados iniciou-se através de pesquisas em plataformas de desenvolvimento colaborativo. As palavras-chave para busca e aquisição do conjunto de dados foram: *wounds*, feridas, ferimentos, *artificial intelligence*, inteligência artificial, *semantic segmentation*, segmentação semântica, *convolution neural network*, *lesion*, lesão, *fracture*, fratura, *ulcer* e úlcera.

Após as pesquisas, foi aderido o repositório da *University of Wisconsin-Milwaukee* na plataforma *Github*, construída pelo laboratório e clínica de colaboração, *Advancing the Zenith of Healthcare (AZH) Wound and Vascular Center*, Milwaukee, WI, dos Estados unidos.

No conjunto de dados escolhido foram contabilizadas 1.210 imagens de úlceras e máscaras binárias de 889 pacientes. As imagens foram tiradas com câmera digital Canon SX 620 HS e iPad Pro sob condições de iluminação não controladas, com fundos diversos. Os profissionais de feridas que realizaram as anotações do conjunto de dados aplicaram técnicas de pré-processamento como cortes e preenchimento com zeros, que é uma técnica usada para aumentar o comprimento dos dados e torná-los compatíveis com outras sequências que possuem diferentes comprimentos.

Após a escolha do conjunto de dados, se tornou necessário a análise e realização de filtros de exclusão dessas imagens baseando-se em alguns critérios. Os critérios de exclusão utilizados foram: imagens que não representam feridas cutâneas e máscaras binárias que não representam a área de ferimentos cutâneos. Assim, foram subtraídas 17 imagens e máscaras binárias deste conjunto de dados, respectivamente, restando um total de 1.193 imagens e máscaras binárias.

O conjunto de dados foi armazenado em disco rígido local e estruturado em uma pasta raiz chamada *train* e duas pastas filhas chamadas de *images*, que continham as imagens das feridas, e *trimaps*, que continham as máscaras binárias. Essa estrutura de diretórios foi utilizada em toda a etapa de execução do treinamento da inteligência artificial.

Em Paralelo ao *Colab*, utilizou-se a nuvem de arquivos da ferramenta *Google Drive*, que é a plataforma pessoal do Google para armazenamento e compartilhamento de arquivos. O conjunto de dados foi transferido e armazenado em um diretório no *Drive* denominado *dataset*. O próximo passo foi criar um notebook no *Google Colaboratory*, onde houve

importação e acesso ao conjunto de dados localizado na unidade de armazenamento do *Google Drive*. Na plataforma, trocou-se o ambiente de execução para GPU por meio da opção de tipo de ambiente.

O *dataset* foi subdividido aleatoriamente em subconjuntos de treinamento, validação e teste. O conjunto de treinamento é usado para treinar o modelo. Durante o treinamento, o modelo ajusta seus parâmetros com base nesses dados. O conjunto de validação é usado para comparar diferentes modelos e hiperparâmetros. A validação ajuda a escolher o melhor modelo e ajustar seus parâmetros para obter o melhor desempenho. O conjunto de teste serve para testar se o modelo realmente funciona com dados não vistos durante o treinamento. A proporção usada nos subconjuntos foi de 70% para treinamento, 15% para validação e 15% para teste.

Logo após foi instanciada a arquitetura de rede neural. A instanciação foi feita com uso de transferência de aprendizado. A transferência de aprendizado é uma técnica que envolve aproveitar o conhecimento adquirido por um modelo pré-treinado em uma tarefa específica e aplicá-lo a uma tarefa relacionada. A transferência de aprendizado permite aproveitar os conhecimentos adquiridos por uma rede neural pré-treinada para resolver tarefas específicas, evitando treinar um modelo do zero.

A rede neural *MobileNetV2* foi instanciada, aproveitando o conjunto de dados *ImageNet* que é uma base de dados em grande escala de imagens anotadas, concebida para ser utilizada na investigação de reconhecimento visual de objetos. Deste modo, a configuração foi concluída e a execução do treinamento da inteligência artificial foi iniciado.

Após a etapa de treinamento da inteligência artificial, foi realizada a escrita do código responsável por extrair as características da máscara binária gerada pelo modelo treinado. O código inclui funções responsáveis por contar pixels que representam o ferimento segmentado pela IA e atribuir esses valores a uma análise comparativa, realizando a subtração entre eles para descobrir a variação entre esses valores.

As medidas obtidas pelos algoritmos no trabalho, são referentes à altura, largura, número de canais de cor e quantidade de pixels das imagens. Os pixels são os menores elementos que compõem uma imagem digital. Cada pixel representa um ponto da imagem e possui uma cor e intensidade específicas. Os valores de cor geralmente são dispostos em escala RGB compostos por três componentes: vermelho, verde e azul (RGB). A combinação desses valores define a cor final do pixel. Quando combinados, os pixels formam a imagem completa possível de visualizar em tela.

As máscaras binárias são imagens de um único canal, onde cada pixel indica se pertence ao objeto de interesse ou ao fundo. Geralmente possuem apenas dois valores de pixel: 0 e 255 (ou 0 e 1, dependendo da escala utilizada). No contexto do trabalho elas representam 2 cores, são elas preto, representado na matriz pelo valor 0 e branco que é representado pelo o valor 1. Os pixels brancos referem-se à representação do ferimento cutâneo e os pretos referem-se ao fundo da imagem.

A área em Pixels das imagens é representada pela fórmula matemática de cálculo de área de retângulo, ou seja, é necessário obter a altura e largura da imagem e multiplicá-las. Para encontrar a área do ferimento basta percorrer a matriz da máscara binária contabilizando os pixels com valor igual a 1. Ao final é encontrado os valores da área total da imagem e área do ferimento cutâneo.

A outra maneira de extrair a área dos ferimentos foi através do método de Monte Carlo. Foram obtidos aleatoriamente ao redor da máscara binária 90% de pontos com base no valor da área total da imagem, que foi obtida pela multiplicação entre sua altura e largura. Os pontos representaram as posições vetoriais da matriz da imagem e foram identificados através dos valores dos pixels, sendo 1 representando o ferimento e 0 o fundo da imagem. Depois foi calculada a proporção do número de pontos do ferimento em relação ao número de pontos gerados. Logo após, multiplicou-se a área total da máscara binária pela proporção de pontos do ferimento.

Para calcular o erro percentual, foi utilizada a média dos valores obtidos pelo método de Monte Carlo em 10 submissões da mesma imagem para cada imagem de teste. Com essa média, o erro percentual foi então calculado pela seguinte fórmula:

$$Erro\ percentual = \frac{|Média\ Área\ Monte\ Carlo - Área\ Pixel\ Counting|}{Área\ Pixel\ Counting} \times 100$$

Para converter as áreas encontradas para o sistema métrico decimal, foi necessário incluir uma referência física ou virtual na imagem original. No contexto do trabalho foi adotado um adesivo da cor azul com unidade fixa no valor de 2 cm². Após incluir a referência, basta identificar na matriz da imagem os pixels condizentes da cor adotada pela referência (azul), assim possuindo um objeto representando dois tipos de unidades, sendo ela em pixels e em centímetros quadrados. Por fim, para encontrar a área do ferimento em centímetros quadrados deve se utilizar uma regra de 3 simples definida pela seguinte fórmula matemática:

$$\text{área da ferida cm}^2 = \frac{\text{área de referência cm}^2 \times \text{área ferida em pixels}}{\text{área de referência em pixels}}$$

Inicialmente, os treinos realizados no *Google Colab*, seguidamente da aplicação dos algoritmos de extração de dimensões, apresentaram resultados promissores, mas com o tempo começaram a surgir impasses. Ao aumentar o número de épocas⁵ para tentar obter melhores resultados, o tempo de execução do treinamento aumentou drasticamente, ocorrendo a quebra do limite de tempo de uso da GPU da plataforma. Quando esse limite era atingido, além de perder o acesso à GPU, a sessão do ambiente de execução era encerrada, levando à perda de todo o progresso feito até aquele ponto.

Devido ao impasse, atingir um valor igual ou superior aos 90% de desempenho do modelo tornou-se uma tarefa difícil. Portanto, para solucionar o problema e obter resultados melhores, estabeleceu-se a meta de aumentar o conjunto de dados para 40.000 imagens de ferimentos cutâneos. Primeiramente, foi optado pela busca por novas imagens. Entretanto, foi descartada devido ao tempo e retrabalho para encontrar esses dados. Após pesquisas em periódicos, foi encontrada uma técnica que permitiu um incremento expressivo no conjunto de dados.

O *Data Augmentation* é um conjunto de técnicas que visa melhorar a qualidade do conjunto de dados usado para treinar modelos de aprendizado de máquina. Ele consiste em aplicar transformações às imagens originais, gerando novas amostras de treinamento. Essas transformações podem incluir rotação, corte, espelhamento e ajuste de contraste. O resultado é um conjunto de dados mais diversificado, que ajuda o modelo a generalizar melhor e a lidar com diferentes variações de imagens. Essas técnicas de aumento de dados foram aplicadas para gerar um conjunto amplo e mais diversificado no trabalho.

As técnicas de *Data Augmentation* aplicadas ao conjunto foram de deslocamento dos eixos x e y da imagem, rotação da posição angular e mudanças de brilho e contraste da imagem. Para cada imagem e máscara binária foram geradas 12 variações de deslocamento de eixos, 12 variações de rotação e 15 variações de brilho e contraste. Contabilizou-se 46.527 imagens e máscaras binárias no conjunto, respectivamente, após o processamento dos algoritmos de aumento de dados.

Todas as imagens foram armazenadas em um diretório raiz denominado *propagated* e suas subpastas seguiram a mesma estrutura inicial, sendo uma subpasta denominada *images*,

⁵ Em inteligência artificial, uma época corresponde a uma passagem completa por todo o conjunto de dados de treinamento durante o processo de aprendizado de um modelo.

contendo as imagens, e a outra denominada *trimaps*, contendo as respectivas máscaras binárias.

Após aumentar o número de dados do conjunto, houve a necessidade de trocar a plataforma de execução do treinamento do modelo. Devido ao volume elevado de dados, o treinamento do modelo ficou bastante lento, resultando em poucas épocas de treinamento e gerando um desempenho abaixo de 90%, ficando distante da meta definida.

A melhoria no treinamento de inteligências artificiais sofre influência de fatores como o *hardware* utilizado, tamanho do lote e número de gerações configuradas na rede neural. Portanto, houve a necessidade de trocar o ambiente de treinamento para que um número maior de dados e épocas fossem comportados. Assim, um ambiente de treinamento mais robusto foi requisitado para que houvesse continuidade aos treinos.

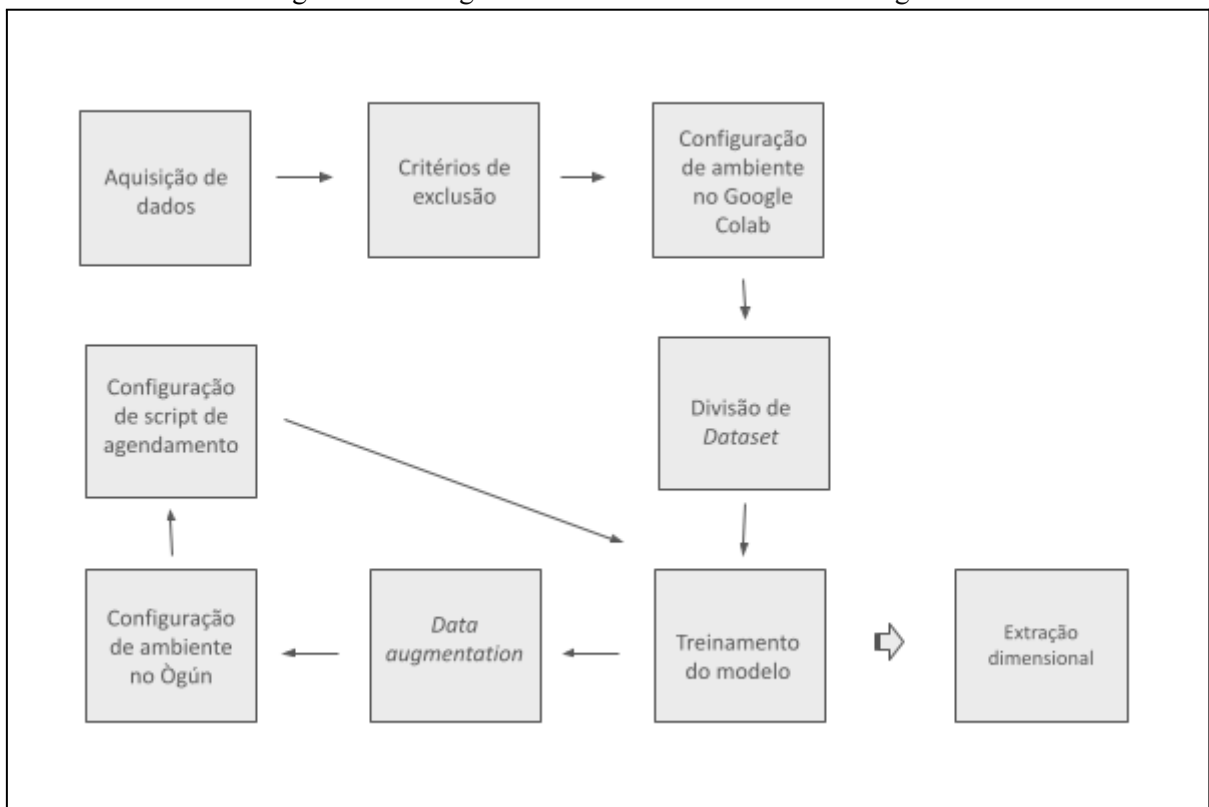
Surgiu então a oportunidade da utilização de um supercomputador através de uma parceria com o Centro de Supercomputação para inovação industrial do Campus Integrado de Manufatura e Tecnologias (SENAI CIMATEC). Um supercomputador é um computador de alto desempenho com capacidade excepcional de processamento e memória. Essas máquinas são essenciais em áreas como a inteligência artificial. Os supercomputadores podem ser montados conectando várias máquinas em rede ou combinando diversos processadores no mesmo espaço físico. Seu papel é crucial para impulsionar avanços científicos e tecnológicos.

Em parceria com o SENAI CIMATEC, levou-se em conta a infraestrutura do supercomputador Ògún para a execução dos treinos. O Ògún é um supercomputador de alta performance (HPC - *High Performance Computing*), capaz de executar 104 trilhões de operações por segundo. Ele é o terceiro supercomputador do Centro de Supercomputação para Inovação Industrial do SENAI CIMATEC e tem como objetivo aprimorar de forma significativa as simulações em áreas como cálculo estrutural, dinâmica de fluidos, montagem de materiais, previsões de eventos e tecnologias de inteligência artificial (Federação das Indústrias do Estado da Bahia - FIEB, 2018).

Para se familiarizar com o ambiente do Ògún foi necessário seguir o manual de uso disponibilizado publicamente na plataforma *Github* através do repositório *muriloboratto/howto-ogbon*. Após aprender os comandos básicos necessários para operação no ambiente, foi necessário transferir o conjunto de dados para lá e elaborar um ambiente virtual de desenvolvimento para criação de *scripts* e downloads de bibliotecas usadas pelo modelo. A transferência dos arquivos foi feita pela rede via protocolo de transferência de arquivos (FTP) e as bibliotecas da linguagem de programação *Python* foram instaladas pelo gerenciador de pacotes padrão (PIP).

O último procedimento feito para treinar o modelo de rede neural no supercomputador Ògún foi a configuração do *script* responsável pelas diretivas de execução e agendamento de tarefas do ambiente. Para executar uma tarefa no Ògún é necessário indicar, por meio do *script*, o nome do processo, número de nós de processamento, partição utilizada, arquivo de log para visualização de status de execução da tarefa, número de tarefas executadas por nó de processamento e os arquivos que serão executados pela tarefa. Após estes procedimentos, os treinos do modelo de rede neural foram realizados. A Figura 8 apresenta o fluxograma das etapas realizadas durante o desenvolvimento metodológico, organizando de forma sequencial os procedimentos adotados ao longo do trabalho.

Figura 8 - Fluxograma do desenvolvimento metodológico



Fonte: Elaborado pelo autor.

4 RESULTADOS E DISCUSSÕES

Ao longo do trabalho de conclusão de curso, os resultados e discussões alcançadas puderam atender aos objetivos propostos. Para atingir os resultados foram realizados os procedimentos elencados conforme descrito no desenvolvimento metodológico.

Os resultados foram estruturados em quatro fases. Na primeira, foi apresentada a evolução do modelo, mostrando as métricas obtidas em cada cenário após o treinamento. Na segunda fase, foram exibidos os resultados do modelo com melhor desempenho. Na terceira fase foi exibida a comparação entre os valores obtidos pelo Método de Monte Carlo e o *Pixel Counting* das máscaras binárias geradas pelo modelo. Por último, na quarta fase foram apresentados os valores obtidos após os procedimentos de conversão de medidas.

A Tabela 1 foi estruturada para apresentar uma série de testes realizados em cada ambiente de treinamento, com destaque para três cenários selecionados no ambiente *Google Colaboratory* e 2 para o ambiente Ògún. Esses cinco *checkpoints* foram escolhidos para resumir a progressão do desempenho das variáveis do modelo conforme a evolução do desenvolvimento. As configurações específicas dos cenários estão detalhadas nos quadros.

Tabela 1 - Configuração dos cenários			
Cenário	Ambiente	Nº de imagens	Nº de épocas
1	Google Colaboratory	1.193	25
2	Google Colaboratory	1.193	50
3	Google colaboratory	1.193	100
4	Ògún	46.527	5
5	Ògún	46.527	20

Fonte: Elaborado pelo autor.

Na Tabela 2, é possível analisar os valores das métricas obtidas após o treinamento do modelo de inteligência artificial, evidenciando de forma detalhada a disposição dos dados obtidos.

Conforme os resultados apresentados na Tabela 2, foi possível identificar uma correlação direta entre o desempenho do modelo e a quantidade de épocas de treinamento. Observou-se que, à medida que o número de épocas aumenta, o desempenho do modelo melhora progressivamente, indicando que treinar por mais épocas contribui para uma maior capacidade de aprendizado e precisão nas previsões.

Tabela 2 - Métricas e resultados dos cenários 1, 2 e 3

Métricas	Cenário 1	Cenário 2	Cenário 3
Nº de imagens	1.193	1.193	1.193
Nº de épocas	25	50	100
Jaccard assertividade	0,02086	0,05542	0,43353
Jaccard perda	- 0,02087	- 0,05545	- 0,43377

Fonte: Elaborado pelo autor.

Em busca de uma melhor percepção do progresso para medir a evolução do desempenho do modelo levou-se em conta a subtração entre o número de épocas definidas e os valores obtidos em cada cenário.

O primeiro intervalo analisado foram os cenários 1 e 2, onde houve um aumento de 100% no número de épocas, que progrediu em 165,67% e 165,69% nas métricas do coeficiente de Jaccard para assertividade e perda, respectivamente. Isso indica uma melhoria média de 165,68% na assertividade da segmentação entre os cenários.

O segundo intervalo analisado foram os cenários 2 e 3, onde houve novamente um aumento de 100% no número de épocas, onde se progrediu 682,26% e 682,27% nas métricas do coeficiente de Jaccard para assertividade e perda, respectivamente. Isso indica uma melhoria de 682,27% na assertividade da segmentação entre os cenários.

Por fim, o último intervalo foi entre os cenários 1 e 3, que resultou em um aumento de 400% no número de épocas, havendo um aumento de 1978,28% e 1978,43% para as métricas do coeficiente de Jaccard para assertividade e perda, respectivamente. Isso indica uma melhoria de 1978,35% na assertividade da segmentação entre os cenários.

A análise dos cenários previstos mostrou que a evolução do modelo se manteve exponencial ao número de épocas definido. Ao adicionar mais épocas ao modelo, o desempenho melhorou significativamente. A evolução se manteve crescente dando um salto entre os cenários 2 e 3. Através disso, foi possível discernir que com mais treinos o modelo atingiria um resultado ainda melhor.

Mesmo com a progressão exponencial exibida entre os cenários, o modelo ainda apresentava erros. A segmentação desempenhada pelo modelo ainda apresentava falsos positivos e negativos, havendo a identificação de áreas desnecessárias e áreas em que deixaram de ser identificadas onde uma ferida realmente estava presente.

O coeficiente de Jaccard, utilizado para avaliar tanto a assertividade quanto a perda, demonstrou valores expressivos, indicando uma precisão crescente na segmentação ao longo

dos cenários. No entanto, embora a média das métricas tenha mostrado evolução significativa, é importante destacar que o desempenho ideal ainda não foi alcançado, atingindo apenas uma média de 43% de precisão. A presença de falsos positivos e negativos sugeriu que o modelo, apesar de promissor, poderia ser otimizado para aumentar sua sensibilidade e especificidade, assegurando uma segmentação mais precisa e minimizando erros.

Foi realizada a validação do modelo gerado com base nos cenários definidos. Para isso, foram conduzidos testes manuais no contexto da segmentação de feridas. Em resumo, esses testes têm como objetivo validar o desempenho do modelo utilizando um conjunto de imagens inéditas, que não fizeram parte do processo de treinamento. O procedimento consiste em submeter essas imagens ao modelo, permitindo uma avaliação visual da eficácia na identificação das feridas.

Ao submeter as imagens é gerada uma máscara binária onde todo o fundo da imagem será exibido em preto e a área correlata a ferida na imagem é representada por brancos. Através desta visualização é possível identificar áreas indesejadas e possíveis causas na segmentação.

As Figuras 9A, 9B, 10A e 10B foram utilizadas no processo de teste e análise visual do modelo correspondente aos cenários 1, 2 e 3. Essas figuras permitiram avaliar o desempenho da segmentação em diferentes condições de entrada.

Figura 9 - A) Imagem original do cenário 3; B) Segmentação gerada por IA referente à Figura 9A



Fonte: A) Wang et al., 2021; B) Elaborado pelo autor.

Figura 10 - A) Imagem original do cenário 3; B) Segmentação gerada por IA referente à Figura 10A



Fonte: A) Wang et al., 2021; B) Elaborado pelo autor.

Através da análise feita com os testes manuais, foi possível observar que o modelo conseguiu desempenhar bem no cenário 3. Entretanto, também foi possível perceber que houve comportamentos indesejados onde a área segmentada da ferida não foi preenchida corretamente, deixando espaços entre ela.

Além disso, a análise revelou a ocorrência de falsos negativos, evidenciada pelos valores do coeficiente de Jaccard nas métricas de assertividade e perda. Esses falsos negativos manifestaram-se na forma de lacunas ou "buracos" nas áreas segmentadas, indicando que partes relevantes da ferida não foram corretamente identificadas. Esses resultados sugerem que, embora o modelo tenha mostrado progresso no cenário 3, ainda há espaço para aprimoramentos. Todas essas características foram vistas nos cenários da Tabela 1.

O desempenho do modelo gerado pelos cenários da Tabela 1 também demonstraram a presença de falsos positivos. Os falsos positivos são caracterizados pela identificação indevida de regiões fora da área real da ferida, o que contribui para o aumento de áreas segmentadas de forma incorreta. Nas Figuras 11A, 11B, 12A e 12B foi possível verificar a presença de falsos positivos mencionados na análise dos cenários 1, 2 e 3.

Portanto, através dos resultados vistos no cenário 3, houve a necessidade de aprimoramento do modelo. O número de imagens foi incrementado através das técnicas de *Data Augmentation* passando de 1.193 para 46.527. O número de épocas também foi alterado,

sendo definido em 5 e 20, respectivamente. Após as alterações nas configurações, foram executados novamente os treinos do modelo.

Figura 11 - A) Imagem original do cenário 3; B) Segmentação gerada por IA com falsos positivos



Fonte: A) Wang et al., 2021; B) Elaborado pelo autor.

Figura 12 - A) Imagem original do cenário 3; B) Segmentação gerada por IA com falsos positivos



Fonte: A) Wang et al., 2021; B) Elaborado pelo autor.

Após executar os treinos no supercomputador Ògún, houve uma reavaliação do desempenho das métricas do modelo. A Tabela 3 exhibe os resultados encontrados após as modificações na configuração do modelo.

Em comparação aos valores obtidos entre os cenários 3 e 4 das Tabelas 2 e 3, respectivamente, foi possível observar um aumento de 68,99% para a métrica de assertividade e 68,90% de perda referente ao coeficiente de Jaccard. A adição de novas imagens ao processo de treinamento contribuiu para a melhoria no desempenho do modelo. Similar aos resultados anteriores mostrados na Tabela 2, o avanço nas métricas continuou a se destacar aumentando o número de épocas de treinamento, conforme ilustrado na Tabela 3.

Tabela 3 - Métricas e resultados dos cenários 4 e 5

Métricas	Cenário 4	Cenário 5
Nº de imagens	46.527	46.527
Nº de épocas	5	20
Jaccard assertividade	0,73263	0,92537
Jaccard perda	- 0,73264	- 0,92541

Fonte: Elaborado pelo autor.


Finalmente, ao expandir o número de épocas de 5 para 20, conforme os cenários 4 e 5, houve um aumento no desempenho das métricas de 26,30% e 26,31% referente a métricas do coeficiente de Jaccard de assertividade e perda, respectivamente. As métricas de assertividade passaram de 0,73263 para 0,92537 e as métricas de perda passaram de - 0,73264 para - 0,92541.

Os resultados obtidos mostraram que, apesar de um menor número de épocas nos cenários da Tabela 3, o modelo apresentou um desempenho superior devido ao aumento no volume de dados utilizados no treinamento. Isso evidencia que a quantidade de dados disponíveis é diretamente proporcional ao desempenho do modelo, contribuindo significativamente para sua eficácia.

Observou-se também que, após o aumento na quantidade de dados, o incremento no número de épocas nos cenários da Tabela 3 contribuiu adicionalmente para a melhoria do desempenho do modelo. Essa combinação mostrou-se eficaz para aprimorar a precisão e a consistência dos resultados. Entretanto, em relação aos avanços observados na Tabela 3, é importante destacar que, à medida que o modelo se aproxima de 100% de precisão, a taxa de evolução reduz significativamente. Esse fenômeno torna o treinamento cada vez mais desafiador e custoso, demandando mais tempo e recursos para alcançar melhorias marginais no desempenho.


Em conformidade com os procedimentos realizados com o modelo dos cenários da Tabela 2, foi feita novamente a análise com testes manuais utilizando o conjunto de imagens. O modelo melhorou significativamente as áreas segmentadas, reduzindo em 83,63% os falsos negativos e 79,37% os falsos positivos, em comparação com o melhor cenário da Tabela 1. As Figuras 13A, 13B, 14A e 14B demonstram os testes manuais realizados.

Figura 13 - A) Imagem original do cenário 5; B) Segmentação gerada por IA referente à Figura 13A



Fonte: A) Wang et al., 2021; B) Elaborado pelo autor.

Figura 14 - A) Imagem original do cenário 5; B) Segmentação gerada por IA referente à Figura 14A



Fonte: A) Wang et al., 2021; B) Elaborado pelo autor.

Através dos testes, foi possível obter uma evolução nos modelos ao longo do treinamento, com aumento nos acertos e redução nos erros. A precisão no posicionamento da área da ferida se destacou, especialmente nas métricas do cenário 5 da Tabela 3, que ultrapassaram 92%.

Para realizar uma avaliação adicional do desempenho do modelo, utilizou-se um novo conjunto de dados, além do conjunto de testes previamente separado para as avaliações dos cenários anteriores. No entanto, como esse conjunto adicional não foi previamente anotado e validado por especialistas da área, optou-se por realizar apenas testes manuais. Estes testes consistiram na visualização e análise das segmentações geradas pelo modelo nas imagens de ferimentos do novo conjunto, permitindo uma verificação visual da precisão sem a necessidade de métricas quantitativas mais detalhadas.


Parte do conjunto de dados Medetec foi extraído para realizar os testes manuais. O conjunto foi disponibilizado e importado também através do repositório da *University of Wisconsin-Milwaukee* na plataforma *Github*. As Figuras 15A, 15B, 16A e 16B exibem os testes manuais com o novo conjunto de dados.

Figura 15 - A) Imagem original Medetec; B) Segmentação gerada por IA referente à Figura 15A



Fonte: A) Wang et al., 2020; B) Elaborado pelo autor.

Figura 16 - A) Imagem original Medetec; B) Segmentação gerada por IA referente à Figura 16A



Fonte: A) Wang et al., 2020; B) Elaborado pelo autor.

Os testes manuais realizados no novo conjunto de dados evidenciaram um desempenho preciso do modelo. As áreas segmentadas apresentaram preenchimento consistente, com poucas lacunas entre os pixels. Foram observados também poucos falsos positivos e negativos.

Apesar do desempenho consistente demonstrado pelo modelo, ainda é necessário realizar aprimoramentos para lidar com a diversidade presente em novos dados. A variação nas características das imagens pode introduzir desafios adicionais para a segmentação, apresentando falsos positivos e negativos. Novos conjuntos de dados que sejam anotados por especialistas podem influenciar positivamente no desempenho do modelo.

Conforme definido no início desta sessão de resultados e discussões, foram realizados procedimentos para extrair a dimensão dos ferimentos segmentados após os treinos dos modelos de inteligência artificial.

A partir dos valores obtidos, foram realizadas comparações entre duas abordagens para extração das dimensões: a contagem de pixels (*Pixel Counting*) na imagem e o método de Monte Carlo, utilizado como estimativa e sujeito a pequenas variações. Para maior detalhamento, foi considerada a média de uma amostra de 10 submissões para cada imagem utilizando o método de Monte Carlo. A Tabela 4 exibe os resultados obtidos com a aplicação desses algoritmos nos cenários de melhor desempenho do modelo treinado pela IA.

Analisando os resultados apresentados na Tabela 4, é possível observar que a diferença entre o *Pixel Counting* e o método de Monte Carlo é pequena, com erros percentuais inferiores a 2% em todas as imagens.

Tabela 4 - resultados dos algoritmos de extração das dimensões

Imagem	Cenário	Pixel Counting	Média Método de Monte Carlo	Erro percentual
Figura 9B	3	911 px	916,4 px	0,5927%
Figura 10B	3	2.148 px	2.138,3 px	0,4536%
Figura 11B	3	795 px	787,3 px	0,9685%
Figura 12B	3	212 px	211,8 px	0,0943%
Figura 13B	5	230 px	233,6 px	1,5652%
Figura 14B	5	2.962 px	2.981,8 px	0,6684%
Figura 15B	5	7.133 px	7.123,9 px	0,1275%
Figura 16B	5	4.113 px	4.040,4 px	1,7651%

Fonte: Elaborado pelo autor.

A partir dos resultados, é possível perceber que ambos os métodos fornecem estimativas de área semelhantes, reforçando a confiabilidade do *Pixel Counting* como medida direta. No entanto, o método de Monte Carlo, ao fornecer uma média de 10 submissões, apresenta uma leve variação nas estimativas, útil para capturar pequenas inconsistências e suavizar flutuações em imagens de bordas irregulares ou qualidade variável. A Tabela 5 apresenta as estatísticas detalhadas do método de Monte Carlo nos cenários de melhor desempenho do modelo treinado em cada ambiente.

Tabela 5 - resultados estatísticos do método de Monte Carlo

Imagem	Cenário	Média	Mediana	Variância	Desvio padrão	Coefficiente de variação
Figura 9B	3	916,4 px	913 px	645,37 px	25,40 px	2,77 %
Figura 10B	3	2138,3 px	2135,5 px	2120,01 px	46,04 px	2,15%
Figura 11B	3	787,3 px	785 px	700,23 px	26,46 px	3,36%
Figura 12B	3	211,8 px	210,5 px	302,62 px	17,39 px	8,21%
Figura 13B	5	233,6 px	230,5 px	107,37 px	10,36 px	4,43%
Figura 14B	5	2981,8 px	2984,5 px	732,40 px	27,06 px	0,90%
Figura 15B	5	7123,9 px	7194,5 px	23080,1 px	151,92 px	2,13%
Figura 16B	5	4040,4 px	4073,5 px	5255,37 px	72,49 px	1,79%

Fonte: Elaborado pelo autor.

As medidas de tendência central extraídas pelo método de Monte Carlo, como a média e a mediana, indicam uma proximidade entre os valores obtidos nas amostras, o que sugere consistência nos resultados. A média aritmética representa o valor médio das áreas estimadas em várias execuções, enquanto a mediana fornece um valor central que reduz a influência de possíveis valores atípicos. A proximidade entre média e mediana nos cenários analisados indica que as distribuições de valores nas amostras são simétricas e não possuem grandes desvios.


A convergência entre as medidas de tendência central reforça a precisão do método de Monte Carlo, apontando que ele se aproxima da área real ao captar variações sutis sem se afastar significativamente do valor médio. Assim, a utilização dessas medidas oferece uma avaliação mais confiável e estável da área estimada, especialmente em imagens onde as variações nas bordas ou a qualidade da imagem podem influenciar os resultados.

Em relação às medidas de dispersão, como o desvio padrão e o coeficiente de variação, indicam que as amostras do método de Monte Carlo possuem uma variabilidade

relativamente baixa. O desvio padrão reflete a dispersão dos valores em torno da média, mostrando que os resultados obtidos em diferentes execuções estão próximos do valor médio, o que evidencia uma estabilidade nas estimativas. Já o coeficiente de variação, que expressa a relação entre o desvio padrão e a média em termos percentuais, reforça essa baixa variabilidade, sugerindo que o método de Monte Carlo é eficiente em fornecer resultados consistentes, mesmo com pequenas flutuações entre as amostras.

Por fim, após a análise comparativa dos métodos aplicados para extrair as dimensões dos ferimentos, foram realizados os procedimentos de conversão das medidas para o sistema métrico decimal. Para isso, considerou-se um adesivo na cor azul com valor definido de 2 cm² em uma região de referência na imagem. A Figura 17 mostra a disposição do procedimento realizado com o adesivo.

Figura 17 - Utilização de adesivo digital para conversão de medidas



Fonte: (Jaganathan et al., 2023).

Um modelo especialista em detectar e segmentar os pixels do adesivo azul foi treinado e validado para garantir a precisão na conversão das medidas. O treinamento do modelo utilizou parte do conjunto de dados já mencionado, complementado por uma amostra proveniente da organização Cicatríbio, que incluiu imagens com os adesivos inseridos. Foram utilizadas uma amostra de 54 imagens que ao aplicar as técnicas de *Data Augmentation*, tornou-se um conjunto de 4.158 imagens no total. O modelo foi treinado com 80 épocas, assegurando que os padrões de segmentação fossem eficazes.

A Figura 18 demonstra os resultados da conversão de medidas aplicadas às amostras de imagens utilizadas no trabalho.

Figura 18 - Resultados da conversão de medidas



Fonte: Elaborado pelo autor.

Para avaliar a variação dos valores obtidos em diferentes posições, cada imagem foi submetida três vezes ao processamento, com capturas realizadas em ângulos ligeiramente diferentes. Em todas as situações, garantiu-se que o ferimento e o adesivo azul permanecessem alinhados com a câmera, posicionada de cima para baixo. Além disso, o Método de Monte Carlo foi submetido 10 vezes para cada imagem, e considerou-se a média dos resultados para a análise. Esse procedimento foi realizado a fim de observar a influência de condições adversas de posicionamento na precisão dos métodos, comparando os valores extraídos pelo *Pixel Counting* e pelo Método de Monte Carlo.

A Tabela 6 demonstra os resultados obtidos da conversão das unidades computacionais (pixels) para sistema métrico decimal em posições adversas, utilizando uma pequena amostra de imagens.

Tabela 6 - resultados da conversão de medidas em posições adversas

Unidade amostral (imagem)	Posição	Pixel Counting	Média Monte Carlo	Pixel Counting cm ²	Média Monte Carlo cm ²	Adesivo px	Adesivo cm ²
1	1	6.745 px	6.748,5 px	4,3251 cm ²	4,3273 cm ²	3.119 px	2 cm ²
1	2	6.331 px	6.371,7 px	3,8805 cm ²	3,9054 cm ²	3.263 px	2 cm ²
1	3	6.351 px	6.319,7 px	3,8880 cm ²	3,8688 cm ²	3.267 px	2 cm ²
2	1	11.961 px	12.075,3 px	6,5576 cm ²	6,6202 cm ²	3.648 px	2 cm ²
2	2	7.316 px	7.274,7 px	7,1306 cm ²	7,0903 cm ²	2.052 px	2 cm ²
2	3	6.882 px	6.903,6 px	7,1242 cm ²	7,1465 cm ²	1.932 px	2 cm ²

Fonte: Elaborado pelo autor.

Através dos resultados planilhados na Tabela 6, foi possível perceber que os valores gerados pela conversão de medidas em ambos os métodos aplicados para extração de dimensões de feridas apresentaram algumas variações em relação à inclinação aplicada em cada posição.

Na primeira unidade amostral, exibida na Tabela 6, foi observado um desvio de 414 pixels no método *Pixel Counting* entre o valor máximo (posição 1) e o valor mínimo (posição 2), equivalente a uma variação de 6,14%. Ao converter estes valores para o sistema métrico decimal foi possível observar um desvio de 0,4446 cm², equivalente a uma variação de 10,28% entre os valores.

Ainda na primeira unidade amostral, exibida na Tabela 6, foi possível observar um desvio de 428,8 pixels no método de Monte Carlo entre o valor máximo (posição 1) e o valor mínimo (posição 3), equivalente a uma variação de 6,35%. Ao converter estes valores para o sistema métrico decimal foi possível observar um desvio de 0,4585 cm², equivalente a uma variação de 10,60% entre os valores.

Para a segunda unidade amostral, exibida na Tabela 6, foi observado um desvio de 5079 pixels no método *Pixel Counting* entre o valor máximo (posição 1) e o valor mínimo (posição 3), equivalente a uma variação de 42,46%. Ao converter os valores máximo e mínimo para o sistema métrico decimal, referente às posições 3 e 1, respectivamente, foi possível observar um desvio de 0,5730 cm², equivalente a uma variação de 8,04%.

Referente ao método de Monte Carlo para a segunda unidade amostral, exibida na Tabela 6, foi observado um desvio de 5171,7 pixels entre o valor máximo (posição 1) e o valor mínimo (posição 3), equivalente a uma variação de 42,83%. Ao converter os valores máximo e mínimo para o sistema métrico decimal, referente às posições 3 e 1, respectivamente, foi possível observar um desvio de 0,5263 cm², equivalente a uma variação de 7,36%.

Neste caso, houve uma pequena diferença em relação a primeira unidade amostral, que teve seus valores paralelos mantendo conformidade entre os valores de maior e menor valor tanto em pixels quanto em centímetros quadrados, nesta segunda unidade amostral os métodos obtiveram uma medida maior ao converter em centímetros quadrados devido a quantidade de pixels segmentadas do adesivo, que é usado como a referência de conversão de valores, aumentando a proporção de valor por pixel, fazendo com que a posição 3 obtivesse maior valor em centímetros mesmo tendo um valor menor em pixels.

Adicionalmente, é possível estabelecer uma relação entre o ângulo da fotografia e o valor extraído em pixels do adesivo. Fotografias com valores de pixels mais próximos para o

adesivo indicam ângulos de inclinação mais similares. Portanto, a consistência nos valores do adesivo pode ser usada como um indicador de uniformidade na captura das imagens, contribuindo para a confiabilidade dos resultados obtidos.

A proporção do adesivo em relação ao ângulo de inclinação da fotografia influencia diretamente os valores extraídos na segmentação. Ao aumentar o número de pixels segmentados do adesivo, o valor em centímetros quadrados da ferida diminui. Por exemplo, se uma ferida possui 1.000 pixels e o adesivo possui 100 pixels, com o valor real do adesivo sendo 2 cm², o cálculo resultará em um valor de 20 cm² para a ferida. Contudo, se o número de pixels do adesivo aumentar para 200, o valor da ferida será reduzido para a metade, possuindo um valor de 10 cm².

Essa relação demonstra a importância de manter um ângulo de inclinação uniforme durante a captura das fotografias, preferencialmente em 90°, com a câmera posicionada diretamente de cima para baixo. A partir da primeira fotografia, os valores em pixels do adesivo podem ser usados como uma referência para ajustar as demais capturas, garantindo maior uniformidade nas posições e alinhamentos das imagens. Este procedimento reduz variações causadas pelo ângulo de inclinação, como também aumenta a precisão das análises, assegurando que os resultados sejam mais consistentes.

5 CONCLUSÃO

A inteligência artificial, com sua importância e proeminência em diversas áreas e aplicações, mostrou-se uma ferramenta eficiente para segmentação semântica de feridas. Por meio dos treinamentos realizados em ambientes computacionais e da implementação de algoritmos de contagem de pixels aliados ao método de Monte Carlo, foi possível extrair dimensões de ferimentos a partir de imagens digitais. Além disso, as características estatísticas do método permitiram a obtenção de análises quantitativas, como medidas de tendência central e dispersão, respondendo assim à questão de pesquisa proposta.

Apesar de não existirem conjuntos de dados rotulados de imagens de ferimentos cutâneos amplamente disponíveis para pesquisas e estudos focados em inteligência artificial, os objetivos deste trabalho foram atingidos. A contextualização, compreensão e aplicação da inteligência artificial como uma ferramenta auxiliar de análise de dimensões de feridas foi realizada através de embasamento teórico e desenvolvimento de uma solução computacional baseada em IA, utilizando o método de Monte Carlo.

Os métodos aplicados foram eficientes, alcançando todos os objetivos dos ciclos do método PDCA. Análises métricas e testes manuais mostraram um desempenho superior a 92% na avaliação da sobreposição de áreas, considerando o coeficiente de Jaccard para assertividade e perda. Com o uso do Método de Monte Carlo foi possível extrair análises quantitativas, identificando a média aritmética, mediana, desvio padrão, coeficiente de variação e o erro percentual em comparação ao método de contagem de pixels (*Pixel Counting*), obtendo as medidas dos ferimentos segmentados.

Tais resultados demonstram a importância de soluções baseadas em inteligência artificial com métodos estatísticos, inovando com novos procedimentos para medir a tendência e precisão de dimensões de figuras irregulares na área médica. Isso abre novas possibilidades para desenvolver procedimentos que resultem em metodologias ainda mais eficazes.

Como trabalhos futuros, é sugerido uma integração e desenvolvimento de aplicações capazes de armazenar, organizar e treinar modelos baseados em inteligência artificial para diferentes categorias de feridas. Com o auxílio de modelos classificadores, os dados podem ser organizados em categorias distintas fazendo com que o modelo de segmentação seja direcionado para categoria de ferida correta, podendo assim aumentar a precisão e desempenho do modelo.

REFERÊNCIAS

- ANDRADE, Fabio Felipe de. **O método de melhorias PDCA**. 2003. Dissertação (Mestrado em Engenharia de Construção Civil e Urbana) - Escola Politécnica, University of São Paulo, São Paulo, 2003. doi:10.11606/D.3.2003.tde-04092003-150859. Acesso em: 25 set 2024.
- A. M. TURING, I.—**COMPUTING MACHINERY AND INTELLIGENCE**, *Mind*, Volume LIX, Issue 236, October 1950, Pages 433–460, <https://doi.org/10.1093/mind/LIX.236.433>
- ALVES, D. F. DOS S. et al.. TRANSLATION AND ADAPTATION OF THE BATES-JENSEN WOUND ASSESSMENT TOOL FOR THE BRAZILIAN CULTURE. **Texto & Contexto - Enfermagem**, v. 24, n. 3, p. 826–833, jul. 2015. Disponível em: <https://doi.org/10.1590/0104-07072015001990014>.
- AKST, Jef. Machine, Learning, 1951. The Scientist, maio 2019. Disponível em: <https://www.the-scientist.com/machine--learning--1951-65792>. Acesso em: 17 maio 2025.
- BIONEXO. **Como a Inteligência Artificial está transformando os hospitais? Uma análise do mapeamento da Anahp patrocinado pela Bionexo**. 10 de out. 2023. Disponível em: https://codigo-healthtech.bionexo.com/inteligencia-artificial-nos-hospitais?utm_source=google&utm_medium=cpc&utm_campaign=TK-Search-DSA-Site&utm_term&gad_source=1&gclid=Cj0KCQjwu8uyBhC6ARIsAKwBGpTmlGITi-ya7c5_wH8oBBmt3F4y7Bnrruj3_DIgXlrHDDRrCyDpwaAtEVEALw_wcB. Acesso em: 26 de maio 2024.
- BLANCE, Andrew. Why hype matters: thinking practically about AI. Towards AI, 26 nov. 2023. Disponível em: <https://pub.towardsai.net/why-hype-matters-thinking-practically-about-ai-aec1409bac66>. Acesso em: 17 maio 2025.
- CARMO, Livia Lourenço do; ZEHRA, Uruij. Sistema tegumentar: anatomia, histologia e funções. Kenhub, 30 out. 2023. Disponível em: <https://www.kenhub.com/pt/library/anatomia/sistema-tegumentar>. Acesso em: 05 Out 2024.
- CARVALHO, A. C. P. DE L. F. DE .. Inteligência Artificial: riscos, benefícios e uso responsável. **Estudos Avançados**, v. 35, n. 101, p. 21–36, jan. 2021. Disponível em: <https://www.scielo.br/j/ea/a/ZnKyrcrLVqzhZbXGgXTwDtn/?format=pdf&lang=pt>. Acesso em: 21 maio 2024.
- CORPO DE BOMBEIROS MILITAR DO PARANÁ. **Ferimentos, curativos e bandagens**. Curitiba: Corpo de Bombeiros Militar do Paraná, 2018. Disponível em: https://www.bombeiros.pr.gov.br/sites/bombeiros/arquivos_restritos/files/documento/2018-12/FerimentosCurativoseBandagens.pdf. Acesso em: 31 maio 2024.
- Costa AM, Matozinhos ACS, Trigueiro PC, Cunha RCG, Moreira LR. **Custos do tratamento de úlceras por pressão em unidade de cuidados prolongados em uma instituição hospitalar de Minas Gerais**. *Enferm Rev*. 2015 [cited 2021 Sep 29];18(1):58–74. Disponível em: <http://periodicos.pucminas.br/index.php/enfermagemrevista/article/view/9378/10327>. Acesso em: 28 Jan. 2025.

CTC TECH. **Inteligência artificial em hospitais: revolucionando o atendimento.**

Disponível em: <https://ctctech.com.br/blog/inteligencia-artificial-em-hospitais/>. 21 de nov. 2023. Acesso em: 19 maio 2024.

DE CASTRO BARBOSA, X. BREVE INTRODUÇÃO À HISTÓRIA DA INTELIGÊNCIA ARTIFICIAL. **Jamaxi**, [S. l.], v. 4, n. 1, 2020. Disponível em:

<https://periodicos.ufac.br/index.php/jamaxi/article/view/4730>. Acesso em: 7 mai. 2024.

DOURADO, D. DE A.; AITH, F. M. A.. The regulation of artificial intelligence for health in Brazil begins with the General Personal Data Protection Law. *Revista de Saúde Pública*, v. 56, p. 80, 2022. Disponível em: <https://doi.org/10.11606/s1518-8787.2022056004461>. Acesso em: 1 jun. 2024.

EQUIPE BLOG PORTAL PÓS. LGPD: o que é e qual sua importância?. *Blog Portal Pós*, 17 jun. 2021. Disponível em: <https://blog.portalpos.com.br/lgpd/>. Acesso em: 17 maio 2025.

FABRIZZIO, G. C.; ERDMANN, A. L.; OLIVEIRA, L. M. DE .. Web App for prediction of hospitalisation in Intensive Care Unit by covid-19. **Revista Brasileira de Enfermagem**, v. 76, n. 6, p. e20220740, 2023. Acesso em: 30 maio 2024.

FALEIROS, Fabiana. Feridas crônicas têm cura?. *D+Informação – USP*, 26 jun. 2018.

Disponível em: <https://demaisinformacao.com.br/feridas-cronicas-tem-cura-sim-saiba-como/>. Acesso em: 17 maio 2025.

FERREIRA, Bruno Eduardo Silva. **Segmentação Semântica de Lesões de Pele utilizando Redes Neurais Convolucionais**. 2018. Monografia (Graduação em Ciência da Computação) - Universidade Federal do Maranhão, São Luís, 2018. Disponível em: <https://monografias.ufma.br/jspui/bitstream/123456789/3532/1/BRUNO-FERREIRA.pdf>. Acesso em: 22 maio 2024.

FIEB. **SENAI CIMATEC amplia capacidade em supercomputação e deverá ser potência no Hemisfério Sul**. Publicado em: 25 out. 2018. Disponível em: <https://www.senaicimatec.com.br/noticias/senai-cimatec-amplia-capacidade-em-supercomputacao-e-devera-ser-potencia-no-hemisferio-sul/>. Acesso em: 08 out. 2024.

JAGANATHAN, Y.; SANOBRE, S.; ALDOSSARY, S. M. A.; ALDOSARI, H. **Validating Wound Severity Assessment via Region-Anchored Convolutional Neural Network Model for Mobile Image-Based Size and Tissue Classification**. *Diagnostics (Basel)*, [s.l.], v. 13, n. 18, p. 2866, 6 set. 2023. DOI: <https://doi.org/10.3390/diagnostics13182866>. PMID: 37761233; PMCID: PMC10529166.

KEKATOS, Mary. What is the Turing Test that determines if computers can think?. *ABC News*, 21 jul. 2023. Disponível em:

<https://abcnews.go.com/US/turing-test-determines-computers/story?id=101486628>. Acesso em: 17 maio 2025.

Langøen, A.; Bianchi, J. In: Flanagan, M. (Org.). **Wound Healing and Skin Integrity: Principles and Practice**. West Sussex: John Wiley & Sons, Ltd., 2013. Capítulo 2, p. 18-32.

LOBO, Luiz Carlos. Inteligência Artificial e Medicina. **Revista Brasileira de Educação Médica [online]**. 2017, v. 41, n. 2 [Acessado 15 Novembro 2023], pp. 185-193. Disponível em: <<https://doi.org/10.1590/1981-52712015v41n2esp>>. ISSN 1981-5271.
<https://doi.org/10.1590/1981-52712015v41n2esp>.

MARINHO, Pedro Rafael Diniz. **Estatística Computacional**. João Pessoa: Universidade Federal da Paraíba, 2021. Disponível em:
https://prdm0.github.io/aulas_computacional/tópicos-em-estatística-computacional.html. Acesso em: 17 maio 2025.

MONTEIRO, Lilian. **IA e robôs injetam benefícios e riscos na medicina**. Estado de Minas, Saúde e Bem Viver, 23 jul. 2023. Disponível em:
https://www.em.com.br/app/noticia/saude-e-bem-viver/2023/07/23/interna_bem_viver,1523096/ia-e-robos-injetam-beneficios-e-riscos-na-medicina.shtml. Acesso em: 26 maio 2024.

MUKHERJEE, S. A.I. versus M.D: what happens when diagnosis is automated? The New Yorker, 3 abr. 2017. Disponível em:
<http://www.newyorker.com/magazine/2017/04/03/ai-versus-md>. Acesso em: 30 nov. 2023.

Phillips CJ, Humphreys I, Fletcher J, Harding K, Chamberlain G, Macey S. **Estimating the costs associated with the management of patients with chronic wounds using linked routine data**. Int Wound J. 2016;13(6):1193–7. doi: <http://dx.doi.org/10.1111/iwj.12443> PubMed PMid: 25818405.

PLANALTO. **Lei n.º 13.709, de 14 de agosto de 2018. Lei Geral de Proteção de Dados Pessoais (LGPD)**. Disponível em:
https://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/lei/113709.htm. Acesso em: 1 jun. 2024.

RUIVO, Alessandra; WERMUTH, Tiago Pacheco; VEIGA, Itiara Gonçalves. **Aplicação do método PDCA em uma indústria processadora de frutas**. Brazilian Journal of Production Engineering, São Mateus, Espírito Santo, Brazil, v. 8, n. 4, p. 119–131, 2022. DOI: 10.47456/bjpe.v8i4.37880. Disponível em: <https://periodicos.ufes.br/bjpe/article/view/37880>. Acesso em: 25 set. 2024.

RUSSELL, Stuart J.; NORVIG, Peter. **Inteligência artificial**. Tradução de Regina Célia Simille. Rio de Janeiro: Elsevier, 2013.

SALINAS DOMJAN, C.; FRANCO, D.; VALENTE, M.. **Modelo computacional y verificación experimental de rendimiento en profundidad en protonterapia para generación de SPREAD OUT BRAGG PEAK (SOBP) en irradiaciones intracraneales**. An. AFA, Buenos Aires, v. 33, n. 2, p. 54-58, abr. 2022. Disponível em:
<https://www.scielo.org.ar/scielo.php?script=sci_arttext&pid=S1850-11682022000200054&lng=es&nrm=iso>. acesso em 14 set. 2024.
<https://dx.doi.org/10.31527/analesafa.2022.33.2.54>.

SALLES, Eduardo. Como utilizar a inteligência artificial na prática da medicina. Medicina S/A, 29 jan. 2024. Disponível em: <https://medicinasa.com.br/ia-medicina-etica/>. Acesso em: 21 maio 2024.

SANAR. **Avaliação clínica e classificação de feridas** | Colunistas. Acervo Comunidade Sanar, 10 jun. 2020. Disponível em: <https://sanarmed.com/avaliacao-clinica-e-classificacao-de-feridas-colunistas/>. Acesso em: 6 jul. 2024.

SICHMAN, J. S.. **Inteligência Artificial e sociedade: avanços e riscos**. Estudos Avançados, v. 35, n. 101, p. 37–50, jan. 2021. Disponível em: <https://doi.org/10.1590/s0103-4014.2021.35101.004>. Acesso em 31 de Abr 2024.

SILVA, Rafael Veiga Teixeira e. Et al. **Inteligência artificial e o teste de Turing: uma análise do prêmio Loebner de 2017 e 2018**. Revista Científica Multidisciplinar Núcleo do Conhecimento. Ano 07, Ed. 03, Vol. 02, pp. 121-141. Março de 2022. ISSN: 2448-0959, Link de acesso: <https://www.nucleodoconhecimento.com.br/tecnologia/premio-loebner>, DOI: 10.32749/nucleodoconhecimento.com.br/tecnologia/premio-loebner. Acesso em: 15 ago. 2023.

SMANIOTTO, Pedro Henrique de Souza et al. Sistematização de curativos para o tratamento clínico das feridas. **Revista Brasileira de Cirurgia Plástica [online]**. 2012, v. 27, n. 4 [Acessado 15 Novembro 2023], pp. 623-626. Disponível em: <<https://doi.org/10.1590/S1983-51752012000400026>>. Epub 29 Maio 2013. ISSN 1983-5175.

SOUSA, Ricardo Cordeiro de. **Desenvolvimento de uma App para Android para fins médicos**. 2018. Mestrado Integrado Engenharia Eletrotécnica e de Computadores – Universidade de Coimbra, Coimbra, 2018. Disponível em: <https://hdl.handle.net/10316/86567>. Acesso em: 21 de set. 2024.

STEPPAN, J.; HANKE, S. **Analysis of skin lesion images with deep learning**. 2021. Disponível em: https://www.semanticscholar.org/paper/Analysis-of-skin-lesion-images-with-deep-learning-g-Steppan-Hanke/2d73e1dbf32c0ab28eae3f20918bfb84b61637f5?utm_source=direct_link. Acesso em: 22 maio 2024.

TECNOLOGIA E PRODUTO. **O ciclo PDCA: um framework de gestão de qualidade**. Vida de Produto, 25 ago. 2020. Disponível em: <https://vidadeproduto.com.br/ciclo-pdca/>. Acesso em: 17 maio 2025.

WANG, C.; ANISUZZAMAN, D. M.; WILLIAMSON, V.; DHAR, M. K.; ROSTAMI, B.; NIEZGODA, J.; GOPALAKRISHNAN, S.; YU, Z. Wound Segmentation: Medetec Foot Ulcer 224 Dataset. GitHub, 2020. Disponível em: https://github.com/uwm-bigdata/wound-segmentation/tree/master/data/Medetec_foot_ulcer_224. Acesso em: 17 maio 2025.

WANG, Chuanbo; MAHBOD, Amirreza; ELLINGER, Isabella; GALDRAN, Adrian; GOPALAKRISHNAN, Sandeep; NIEZGODA, Jeffrey; YU, Zeyun. FUSeg: The Foot Ulcer Segmentation Challenge. GitHub, 2021. Disponível em: <https://github.com/uwm-bigdata/wound-segmentation/tree/master/data/Foot%20Ulcer%20Segmentation%20Challenge>. Acesso em: 17 maio 2025.

YORIYAZ, H. **Método de Monte Carlo: princípios e aplicações em Física Médica**. Revista Brasileira de Física Médica, [S. l.], v. 3, n. 1, p. 141–149, 2015. DOI: 10.29384/rbfm.2009.v3.n1.p141-149. Disponível em: <https://www.rbfm.org.br/rbfm/article/view/52>. Acesso em: 23 set. 2024.