



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Rodrigo de Paula e Silva Ribeiro

**Avaliação Automatizada de Qualidade e Adesão ao Protocolo de Aquisição de
Imagens em Exames de Teledermatologia**

Florianópolis
2023

Rodrigo de Paula e Silva Ribeiro

**Avaliação Automatizada de Qualidade e Adesão ao Protocolo de Aquisição de
Imagens em Exames de Teledermatologia**

Dissertação submetida ao Programa de Pós-Graduação
em Ciência da Computação da Universidade Fede-
ral de Santa Catarina para a obtenção do título de mes-
tre em Ciência da Computação.

Orientador: Prof. Aldo von Wangenheim, Dr. rer. nat.

Florianópolis
2023

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Ribeiro, Rodrigo de Paula e Silva
Avaliação Automatizada de Qualidade e Adesão ao
Protocolo de Aquisição de Imagens em Exames de
Tele dermatologia / Rodrigo de Paula e Silva Ribeiro ;
orientador, Aldo von Wangenheim, 2023.
62 p.

Dissertação (mestrado) - Universidade Federal de Santa
Catarina, Centro Tecnológico, Programa de Pós-Graduação em
Ciência da Computação, Florianópolis, 2023.

Inclui referências.

1. Ciência da Computação. 2. Telemedicina. 3.
Tele dermatologia. 4. Aprendizado de Máquina. 5.
Processamento de Imagem. I. von Wangenheim, Aldo. II.
Universidade Federal de Santa Catarina. Programa de Pós
Graduação em Ciência da Computação. III. Título.

Rodrigo de Paula e Silva Ribeiro

Avaliação Automatizada de Qualidade e Adesão ao Protocolo de Aquisição de Imagens em Exames de Teledermatologia

O presente trabalho em nível de mestrado foi avaliado e aprovado por banca examinadora composta pelos seguintes membros:

Prof. Mauro Roisenberg, Dr.
Universidade Federal de Santa Catarina

Prof. Daniel Holthausen Nunes , Dr.
Universidade Federal de Santa Catarina

Prof. Antonio Carlos Sobieranski, Dr.
Universidade Federal de Santa Catarina

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi julgado adequado para obtenção do título de mestre em Ciência da Computação.

Coordenação do Programa de
Pós-Graduação

Prof. Aldo von Wangenheim, Dr. rer. nat.
Orientador

Florianópolis, 2023.

Dedico este trabalho ao meu pai Francisco e a querida Rany, que estiveram presentes ao início desta jornada, e agora me acompanham de outro plano nesta conclusão.

(in memoriam)

AGRADECIMENTOS

Gostaria de agradecer, primeiramente, ao meu orientador, Prof. Dr. rer. nat. Aldo von Wangenheim, pela parceria e confiança depositada, principalmente pela paciência e transmissão de seus conhecimentos, sem os quais este trabalho não seria possível. Estendo meus agradecimentos a todos os professores que fizeram parte de todos os níveis de minha educação; sem eles, hoje eu nada seria. Agradeço imensamente a toda a equipe do STT/SC pela oportunidade de trabalhar com dados reais do sistema, o que trouxe muita robustez para esta pesquisa, em especial, agradeço ao Mestre Harley Miguel Wagner, Dr. Alexandre Savaris e ao Prof. Dr. Daniel Holthausen Nunes pela cordialidade, receptividade e discussões frutíferas que foram essenciais para a delimitação e enfoque da necessidade deste trabalho.

Agradeço também à Universidade Federal de Santa Catarina e ao Programa de Pós-Graduação em Ciência da Computação pela oportunidade de evoluir em mais uma etapa de minha caminhada acadêmica. Registro meus agradecimentos à Fundação de Amparo à Pesquisa e Inovação do Estado de Santa Catarina pelo apoio parcial durante esta jornada do mestrado (0398/2021). Agradeço aos membros da banca avaliadora: Prof. Dr. Mauro Roisenberg, Prof. Dr. Antonio Carlos Sobieranski e Prof. Dr. Daniel Holthausen Nunes, por aceitarem o convite tanto na etapa de qualificação quanto na etapa de defesa, de forma que seus comentários pontuais contribuíram para a elevação deste trabalho.

Por fim, gostaria de agradecer àqueles que foram meu apoio e fonte de energia para superar todos os obstáculos e intempéries sofridos durante este período: minha esposa Fernanda e meus filhos Gustavo, Guilherme e Júlia, que constantemente me fazem lembrar dos motivos pelos quais certos sacrifícios valem a pena.

*“O conhecimento é uma aventura em aberto.
O que significa que aquilo que saberemos amanhã
é algo que desconhecemos hoje;
e esse algo pode mudar as verdades de ontem.”
(POPPER, Karl)*

RESUMO

A avaliação da qualidade da imagem e da adesão ao protocolo de aquisição é uma área negligenciada na tele dermatologia. Neste trabalho abordamos esse problema examinando se é viável utilizar métodos de aprendizado de máquina para automatizar a avaliação da aderência de exames a protocolos de aquisição de imagens. Utilizamos um conjunto de dados composto por 36.102 exames tele dermatológicos realizados no Sistema Integrado de Telemedicina e Telessaúde do Estado de Santa Catarina (STT/SC) durante o ano de 2021. Neste estudo focamos nos critérios de qualidade de dois protocolos de aquisição de imagens: (a) Imagem de Aproximação (b) Imagem Panorâmica, pois estão presentes em todos os protocolos de exames de tele dermatologia atualmente empregados pelo STT/SC. Como nosso processo de validação, adotamos métricas padrão de aprendizado de máquina e um estudo de concordância entre avaliadores com 11 dermatologistas. Para o protocolo de imagem de aproximação, empregamos a Mask-RCNN, uma arquitetura baseada em aprendizado profundo para detecção e segmentação de objetos, para identificar a presença de uma etiqueta de identificação da lesão e uma régua usada para fornecer uma referência de tamanho da lesão. Este método alcançou uma pontuação de 96% mAP. Para o protocolo de imagem panorâmica, empregamos Densepose, uma arquitetura de Aprendizado Profundo de estimativa de pose humana para avaliar a presença de todo o corpo do paciente e sua orientação. Este método apresentou 75% mAP. A combinação das duas abordagens foi adicionalmente validada através de um estudo de concordância interavaliadores entre especialistas e alcançou um nível de concordância de 96,68% com o método alfa de Krippendorff. Nossos resultados demonstram que é viável utilizar técnicas baseadas em aprendizado de máquina para automatizar a avaliação da qualidade da imagem e da adesão ao protocolo em tele dermatologia, antes da análise manual do exame pelo especialista.

Palavras-chave: Telemedicina. Tele dermatologia. Aprendizado de Máquina. Processamento de Imagem.

ABSTRACT

Image quality and acquisition protocol adherence assessment is a neglected area in teledermatology. In this work we address this problem by examining if it is feasible to use machine learning methods to automate the assessment of the adherence of examinations to image acquisition protocols. We employed a dataset composed of 36102 tele-dermatological examinations performed at the Santa Catarina State Integrated Telemedicine and Telehealth System (STT/SC) during the year of 2021. In this study we focused on the quality criteria of two image acquisition protocols: (a) Approximation Image (b) Panoramic Image, as these are present in all teledermatology examination protocols currently employed by STT/SC. As our validation process, we adopted standard machine learning metrics and an inter-rater agreement study with 11 dermatologists. For the Approximation Image protocol, we employed the Mask-RCNN Object Detection Deep Learning architecture to identify the presence of a lesion identification tag and a ruler used to provide a frame reference of the lesion. This method achieved a score of 96% mAP. For the Panoramic Image protocol we employed Densepose, a human pose estimation Deep Learning architecture to assess the presence of a whole patient body and its orientation. This method presented 75% mAP. A combination of the two approaches was additionally validated through an inter-rater agreement study between specialists and achieved a level of agreement of 96.68% with the Krippendorff alpha score. Our results show the feasibility of machine learning based techniques to automate the image quality and protocol adherence assessment in teledermatology, prior to the specialist's manual analysis of the examination.

Keywords: : Telemedicine. Teledermatology. Machine Learning. Image processing.

LISTA DE FIGURAS

| | |
|--|----|
| Figura 1 – Exemplo de foto panorâmica como descrito no manual técnico do STT/SC. | 16 |
| Figura 2 – Foto de aproximação (esquerda) e foto dermatoscópica (direita) como descrito no manual técnico do STT/SC. | 17 |
| Figura 3 – Proporção entre exames válidos e inválidos por ano, mostrando contagem de inválidos. | 19 |
| Figura 4 – Cenário de aplicação | 21 |
| Figura 5 – Panorama esquemático dos protocolos de exame e aquisição de imagens na Teledermatologia. | 24 |
| Figura 6 – Ilustração Protocolo Câncer de Pele | 25 |
| Figura 7 – Fluxo base <i>Machine Learning</i> aplicado a classificação de imagem | 26 |
| Figura 8 – Fluxo base <i>Deep Learning</i> aplicado a classificação de imagem | 27 |
| Figura 9 – Diferenças entra as principais tarefas de visão computacional. | 28 |
| Figura 10 – Diferenças entra os tipos de Segmentação. | 28 |
| Figura 11 – Modelos de Human Pose Estimation. | 29 |
| Figura 12 – Sequência de execução da revisão | 32 |
| Figura 13 – Pipeline de execução TrueImage | 33 |
| Figura 14 – Resultado da Revisão: Gráfico de Publicações por Ano | 35 |
| Figura 15 – Distribuição das imagens entre os subconjuntos para etiqueta e régua. | 38 |
| Figura 16 – Ilustração do Modelo CSE DensePose com as partes segmentadas. | 42 |
| Figura 17 – Exemplo visual de resultados do método de aproximação detectando diferentes tipos de régua e etiquetas | 45 |
| Figura 18 – Matrizes de confusão para o método de imagens panorâmicas. | 47 |
| Figura 19 – Exemplo visual simulado do resultado no método para imagens panorâmicas | 47 |
| Figura 20 – Exemplo visual simulado em que houve confusão no método para imagens panorâmicas | 48 |

LISTA DE QUADROS

| | |
|---|----|
| Quadro 1 – Definição do protocolo utilizado na busca. | 31 |
| Quadro 2 – Códigos de Invalidação de exames. | 59 |

LISTA DE TABELAS

| | |
|---|----|
| Tabela 1 – Compilado dos Resultados das Buscas. | 31 |
| Tabela 2 – Distribuição das anotações entre os subconjuntos de etiqueta e régua. | 38 |
| Tabela 3 – Questões do acordo entre avaliadores. | 43 |
| Tabela 4 – Métricas mAP (padrão) e mAP com limiar de 0.75 nos conjuntos de validação e teste. | 44 |
| Tabela 5 – Métricas mAP (padrão) e mAP com limiar de 0.75 no método de imagens panorâmicas | 46 |
| Tabela 6 – Métricas auxiliares: FScore, Precision e Recall para o método de imagens panorâmicas | 46 |
| Tabela 7 – Relatório Artigos Excluídos | 58 |
| Tabela 8 – Matriz do Acordo entre Avaliadores | 60 |
| Tabela 9 – Fscore, Precision e Recall no conjunto padrão de panorâmicas por classe. | 62 |
| Tabela 10 – Fscore, Precision e Recall no conjunto rotacionado de panorâmicas por classe. | 62 |

LISTA DE ABREVIATURAS E SIGLAS

| | |
|----------|--|
| AP | <i>Average Precision</i> |
| AR | <i>Agreement Rate</i> |
| BB | <i>Bounding Box</i> |
| CNN | <i>Convolutional Neural Network</i> |
| CO | <i>Convolution Operator</i> |
| COCO | <i>Common Objects in Context</i> |
| CSE | <i>Continuous Surface Embeddings</i> |
| DICOM-SR | <i>Structured Reporting objects in the Digital Imaging and Communications in Medicine - DICOM 3.0 - standard</i> |
| DL | <i>Deep Learning</i> |
| EUA | Estados Unidos da América |
| FAIR | <i>Facebook Artificial Intelligence Research</i> |
| FN | <i>False Negative</i> |
| FP | <i>False Positive</i> |
| HPE | <i>Human Pose Estimation</i> |
| IA | Inteligência Artificial |
| IoU | <i>Intersect Over Union</i> |
| IRA | <i>Inter-Rater Agreement</i> |
| mAP | <i>Mean Average Precision</i> |
| ML | <i>Machine Learning</i> |
| MSRA | <i>Microsoft Research Asia</i> |
| RCNN | <i>Region based Convolutional Neural Network</i> |
| RNA | Redes Neurais Artificiais |
| SQL | <i>Structured Query Language</i> |
| STT/SC | Sistema Integrado Catarinense de Telemedicina e Telessaúde |
| TD | Teledermatologia |
| TP | <i>True Positive</i> |
| UBS | Unidade Básica de Saúde |
| VC | Visão Computacional |

SUMÁRIO

| | | |
|--------------|--|-----------|
| 1 | INTRODUÇÃO | 15 |
| 1.1 | MOTIVAÇÃO E JUSTIFICATIVA | 17 |
| 1.2 | HIPÓTESE | 19 |
| 1.3 | OBJETIVOS | 19 |
| 1.3.1 | Objetivo Geral | 19 |
| 1.3.2 | Objetivos Específicos | 20 |
| 1.3.3 | Cenário de Aplicação | 20 |
| 1.3.4 | Metodologia | 20 |
| 1.3.5 | Estrutura da Dissertação | 22 |
| 2 | FUNDAMENTAÇÃO TEÓRICA | 23 |
| 2.1 | PROTOCOLOS DE AQUISIÇÃO DE IMAGENS NO STT/SC | 23 |
| 2.1.1 | Protocolo Câncer de Pele | 23 |
| 2.1.2 | Protocolo Outras Dermatoses | 24 |
| 2.2 | INTELIGÊNCIA ARTIFICIAL | 25 |
| 2.2.1 | Aprendizado de Máquina | 26 |
| 2.2.2 | Aprendizado Profundo | 26 |
| 2.3 | VISÃO COMPUTACIONAL | 27 |
| 2.4 | HUMAN POSE ESTIMATION | 28 |
| 3 | TRABALHOS CORRELATOS | 30 |
| 3.1 | DEFINIÇÕES DA BUSCA | 30 |
| 3.2 | EXECUÇÃO DA BUSCA | 30 |
| 3.3 | DISCUSSÃO DOS RESULTADOS DA BUSCA | 31 |
| 3.4 | AMEAÇA A PESQUISA | 33 |
| 4 | PROPOSTA PARA CRÍTICA DOS PROTOCOLOS | 36 |
| 4.1 | DELIMITAÇÃO DO ESCOPO | 36 |
| 4.2 | MATERIAIS | 36 |
| 4.2.1 | <i>Dataset</i> para identificação de etiqueta e régua | 37 |
| 4.2.2 | <i>Dataset</i> para imagens panorâmicas | 38 |
| 4.3 | MÉTODOS DE PROCESSAMENTO DE IMAGEM | 39 |
| 4.3.1 | Identificação da etiqueta de informações da lesão e régua | 40 |
| 4.3.2 | Identificação de Pose | 41 |
| 4.4 | MÉTODOS DE AVALIAÇÃO | 41 |
| 4.4.1 | Validação de aprendizado de máquina tradicional | 41 |
| 4.4.2 | Validação humana por acordo entre avaliadores | 42 |
| 5 | RESULTADOS | 44 |
| 5.1 | FOTO DE APROXIMAÇÃO COM RÉGUA | 44 |
| 5.2 | FOTO PANORÂMICA | 45 |

| | | |
|----------|--|-----------|
| 5.3 | CONCORDÂNCIA ENTRE AVALIADORES | 48 |
| 6 | CONSIDERAÇÕES FINAIS | 49 |
| 6.1 | CONCLUSÃO | 49 |
| 6.2 | TRABALHOS FUTUROS | 50 |
| 6.3 | ÉTICA E DISPONIBILIDADE DOS DADOS | 51 |
| | REFERÊNCIAS | 52 |
| | APÊNDICE A – LISTA DE ARTIGOS COM MOTIVOS DE EXCLUSÃO | 58 |
| | APÊNDICE B – CÓDIGOS DE INVALIDAÇÃO DO STT/SC | 59 |
| | APÊNDICE C – MATRIZ DO INTER-RATER AGREEMENT (IRA) . | 60 |
| | APÊNDICE D – EQUAÇÕES DAS MÉTRICAS DE AVALIAÇÃO . . | 61 |
| | APÊNDICE E – MÉTRICAS COMPLEMENTARES FSCORE, PRE- CISION E RECALL POR CLASSE NO MÉTODO DE IMAGENS PANORÂMICAS | 62 |

1 INTRODUÇÃO

A telemedicina é a aplicação da tecnologia de telecomunicações para permitir uma assistência à saúde mais ampla, pois permite a consulta especializada sem a necessidade de que o paciente percorra longas distâncias (HIGH *et al.*, 2000; LEVIN; WARSHAW, 2009).

A dermatologia como afirmado por Mckoy *et al.* (2016) é particularmente adequada para a telemedicina porque as doenças de pele são visíveis ao olho humano e as informações clínicas podem ser digitalmente adquiridas, armazenadas e transmitidas para um diagnóstico preciso e tratamento adequado na maioria dos casos. Em situações que requerem biópsia, também é possível a análise de forma que o encaminhamento apropriado possa ser feito rapidamente.

A prática da teledermatologia (TD) pode aliviar a má distribuição de cuidados especializados e permitir que pacientes não localizados nas proximidades geográficas de recursos especializados recebam cuidados (LEVIN; WARSHAW, 2009; ROMERO; GARRIDO; GARCIA-ARPA, 2008; MAIA; WANGENHEIM; NOBRE, 2006).

Neste contexto a teledermatologia é a dermatologia tradicional aplicada a telemedicina, e segundo Mckoy *et al.* (2016), Cristiana Silva *et al.* (2009), Lasierra *et al.* (2012) e Romero, Garrido e Garcia-Arpa (2008), pode ser classificada de duas formas:

Assíncrona, em que os dados de um paciente são enviados e armazenados em um banco de dados e depois encaminhados ao especialista para avaliação.

Síncrona, ou "em tempo real", quando paciente e especialista interagem em tempo real por meio de videoconferência.

Como as imagens constituem a principal fonte de informação para dermatologistas realizarem um diagnóstico na teledermatologia, existem vários fatores de qualidade que precisam de atenção especial e padronização para um diagnóstico válido (LASIERRA *et al.*, 2012; MCKOY *et al.*, 2016).

No estudo, "Creating a Web Infrastructure for the Support of Clinical Protocols and Clinical Management: An Example in Teledermatology", desenvolvido por Wangenheim e Nunes (2018a), os autores descrevem os protocolos que foram implementados no estado de Santa Catarina como parte do sistema integrado de telemedicina e tele-saúde de Santa Catarina (STT/SC) para promover um padrão de captura de imagens de forma a reduzir as imagens inválidas e melhorar o diagnóstico remoto.

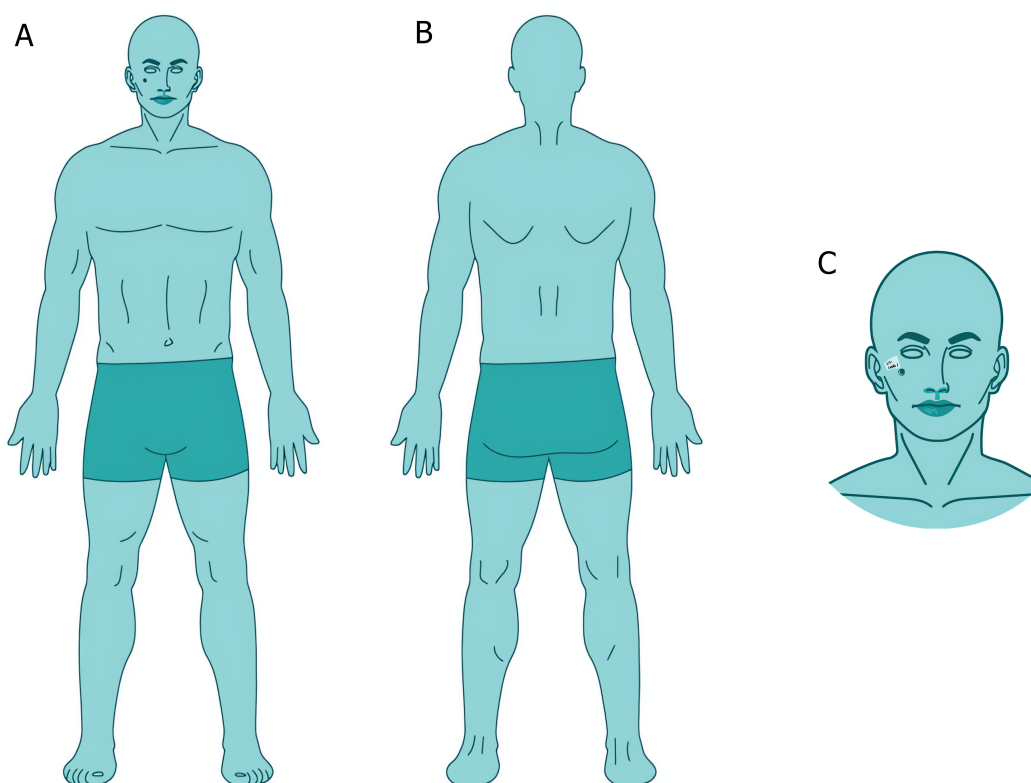
Os protocolos descritos por Wangenheim, Nunes e Wagner (2019) e posteriormente atualizados por Wagner e Picolotto de Lara (2022) possuem características diferentes com base no tipo de lesão que está sendo analisada. Os tipos de fotos que são regidas por estes protocolos são:

- Foto Panorâmica.

- Foto de Aproximação com Régua.
- Foto de Contato (Dermatoscópica).

O protocolo de fotos panorâmicas é composto por três fotos: (a) frente, (b) costas e (c) região afetada, como demonstra a Figura 1.

Figura 1 – Exemplo de foto panorâmica como descrito no manual técnico do STT/SC.

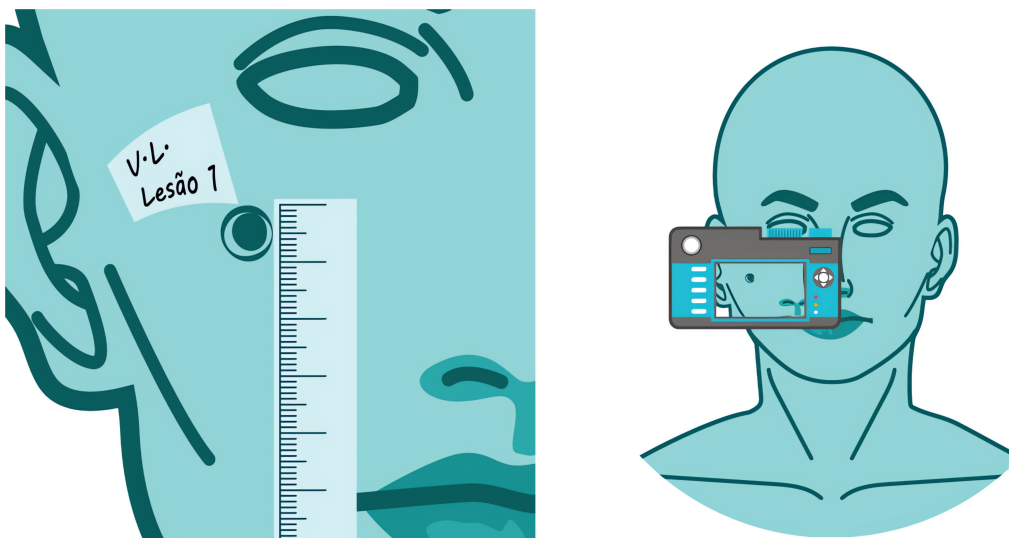


Fonte: Adaptado de Wagner e Picolotto de Lara (2022)

As fotos de aproximação com régua devem possuir uma régua branca ao longo da lesão, e as fotos de contato (dermatoscópico) são realizadas com contato direto com a região lesionada e em caso de a lesão ser maior do que o dispositivo pode capturar, são tiradas várias fotos de diferentes porções da região afetada. A Figura 2 ilustra os dois exemplos.

Todos os protocolos são executados por um operador designado no centro de atenção primária. Esses profissionais recebem treinamento e suporte adequados na implementação dos protocolos (WANGENHEIM; NUNES; WAGNER, 2019; WAGNER; PICOLOTTO DE LARA, 2022).

Figura 2 – Foto de aproximação (esquerda) e foto dermatoscópica (direita) como descrito no manual técnico do STT/SC.



Fonte: Adaptado de Wagner e Picolotto de Lara (2022)

1.1 MOTIVAÇÃO E JUSTIFICATIVA

As pesquisas sobre análise automatizada de imagens em dermatologia começaram há mais de 20 anos (POMPL *et al.*, 2000, 1999). Desde então, tem se concentrado no apoio diagnóstico, principalmente no diagnóstico de melanoma (THOMSEN *et al.*, 2019; GOMOLIN *et al.*, 2020; PAI, V. V.; PAI, R. B., 2021), tendo a eficácia, generalização e confiabilidade dos diagnósticos fornecidos por tais métodos, como alvo de crítica por alguns autores (NAVARRETE-DECHENT *et al.*, 2018). Outras áreas potenciais de aplicação da análise automatizada de imagens em dermatologia, como a avaliação automatizada da qualidade da imagem e a adesão aos protocolos de exame e aquisição de imagens, têm sido negligenciadas (THOMSEN *et al.*, 2019; CHAN *et al.*, 2020; GOMOLIN *et al.*, 2020; PAI, V. V.; PAI, R. B., 2021).

Imagens de alta qualidade e padronizadas são imprescindíveis para reduzir a necessidade de consultas presenciais ou que o paciente retorne à unidade básica para refazer os exames (LANDOW *et al.*, 2014). Porém, na maioria dos casos, o operador que realiza a aquisição de imagens não é um fotógrafo bem treinado, mas sim um enfermeiro ou técnico da unidade básica de saúde que recebeu o treinamento para seguir os protocolos de aquisição de imagens (WANGENHEIM; NUNES, 2018a; LEVIN; WARSHAW, 2009; LANDOW *et al.*, 2014). Atualmente no Brasil esses cargos também possuem grande rotatividade, de forma que o técnico já acostumado com a rotina é trocado por outro recém treinado, o que leva a eventuais erros durante a fase de aquisição das imagens dos pacientes.

No Estado de Santa Catarina, no Brasil, devido à composição demográfica do


Estado, o câncer de pele representa uma doença com taxas de morbidade de alta preocupação epidemiológica. Em 2023, segundo o Instituto Nacional do Câncer, mais de 38% dos novos casos de câncer serão neoplasias de pele. A estimativa de incidência para 2023 é de 193,34 novos casos por 100 mil habitantes. As neoplasias cutâneas melanoma e não melanoma são, juntas, os tipos de câncer mais comuns em Santa Catarina (INCA, 2023). Felizmente, Santa Catarina possui uma rede de telemedicina assíncrona de grande escala que cobre 100% do Estado e está em operação há mais de 15 anos, integrando a atenção primária, secundária e terciária em uma única infraestrutura: o Sistema Integrado de Telemedicina e Telessaúde do Estado de Santa Catarina (STT/SC) (INACIO *et al.*, 2014; WANGENHEIM; NUNES, 2018a; MAIA; WANGENHEIM; NOBRE, 2006). A existência desse sistema facilitou o desenvolvimento de um modelo ampliado de teledermatologia, capaz de integrar todo o setor dermatológico no processo de atendimento desta infraestrutura de telemedicina e telessaúde. Entre janeiro/2014 e dezembro/2021, o STT/SC processou 192.112 exames teledermatológicos realizados em unidades básicas de saúde (UBS) que necessitaram de triagem teledermatológica de pacientes. Um total de 179.255 (93,30%) desses exames foram considerados realizados corretamente do ponto de vista da qualidade da imagem e do protocolo de aquisição. Isso significa que entre janeiro/2014 e dezembro/2021 um total de 12.857 exames de teledermatologia foram invalidados e precisaram ser repetidos. O gráfico da Figura 3 ilustra a quantidade de exames inválidos observados no STT/SC entre os anos de 2014 e 2021.

Segundo o estudo "*Direct Impact on Costs of the Teledermatology-Centered Patient Triage in the State of Santa Catarina - Analysis of the 2014-2018 Data*", dos autores Wangenheim e Nunes (2018b), as maiores causas de um exame invalidado por dermatologistas no contexto do STT/SC são:

- a imagens adquiridas empregando um protocolo de aquisição de imagens em discordância com a hipótese diagnóstica/patologia a ser estudada no exame.
- b protocolo de aquisição executado incorretamente.
- c imagens de qualidade excessivamente ruim.

Portanto, um método que possa verificar a conformidade com os protocolos em tempo real de modo a identificar e dar feedback sobre possíveis erros para o operador, é desejável para reduzir ainda mais o número de exames inválidos e auxiliar em um encaminhamento mais rápido e eficaz, evitando que o paciente que more longe dos postos de atendimentos tenha que fazer outro deslocamento e aguardar mais tempo para encaminhamento e diagnóstico por conta de erros na aquisição das imagens.

Figura 3 – Proporção entre exames válidos e inválidos por ano, mostrando contagem de inválidos.



Fonte: Elaborado pelo autor com base nos dados do STT/SC (2023)

1.2 HIPÓTESE

A quantidade de exames inválidos na teledermatologia do STT/SC é um problema relevante e que gera desgastes ao paciente, equipe de atendimento e médicos. As abordagens existentes para padronizar e melhorar a receptividade de exames chegou a um platô de rejeição aonde não se observam melhorias na redução da taxa de exames inválidos. Neste contexto, pretende-se, ao longo deste trabalho, responder a seguinte pergunta de pesquisa: é possível automatizar a análise crítica dos protocolos de aquisição de imagens em teledermatologia com o uso de técnicas de Visão Computacional baseadas em *Deep Learning* (DL) de forma a melhorar a taxa de rejeição de exames teledermatológicos no STT/SC?

1.3 OBJETIVOS

Nas seções abaixo estão descritos o objetivo geral e os objetivos específicos desta pesquisa.

1.3.1 Objetivo Geral

De forma a verificar a hipótese apresentada, este projeto de pesquisa tem como objetivo geral propôr e testar um conjunto de técnicas que possa fornecer *feedback*

em tempo real sobre a aderência os protocolos de aquisição de imagens de teledermatologia com base nos protocolos do STT/SC.

1.3.2 Objetivos Específicos

De maneira específica, este trabalho busca:

1. Explorar os dados do STT/SC de forma a definir onde ocorrem os erros na teledermatologia.
2. Delimitar quais as tarefas de visão computacional são apropriadas a cada protocolo.
3. Identificar as técnicas de visão computacional estado da arte que possam ser aplicadas individualmente nos protocolos de aquisição de imagens.
4. Propor, testar e validar um conjunto de técnicas para análise crítica de imagens teledermatológicas de acordo com os protocolos do STT/SC.

1.3.3 Cenário de Aplicação

Em um cenário de aplicação as técnicas propostas neste trabalho são inserida em um módulo auxiliar que irá analisar as imagens coletadas pelo operador do sistema básico de saúde e dará *feedback* sobre quais imagens e/ou protocolos estão incorretos. No caso em que todas as imagens estejam de acordo com os protocolos, o módulo marcará então como pronto para enviar para o sistema, ou, em caso de não estarem de acordo com os protocolos, retornará ao operador para que ele decida com base no *feedback* se é necessário realizar novamente o exame. Este fluxo é ilustrado na Figura 4.

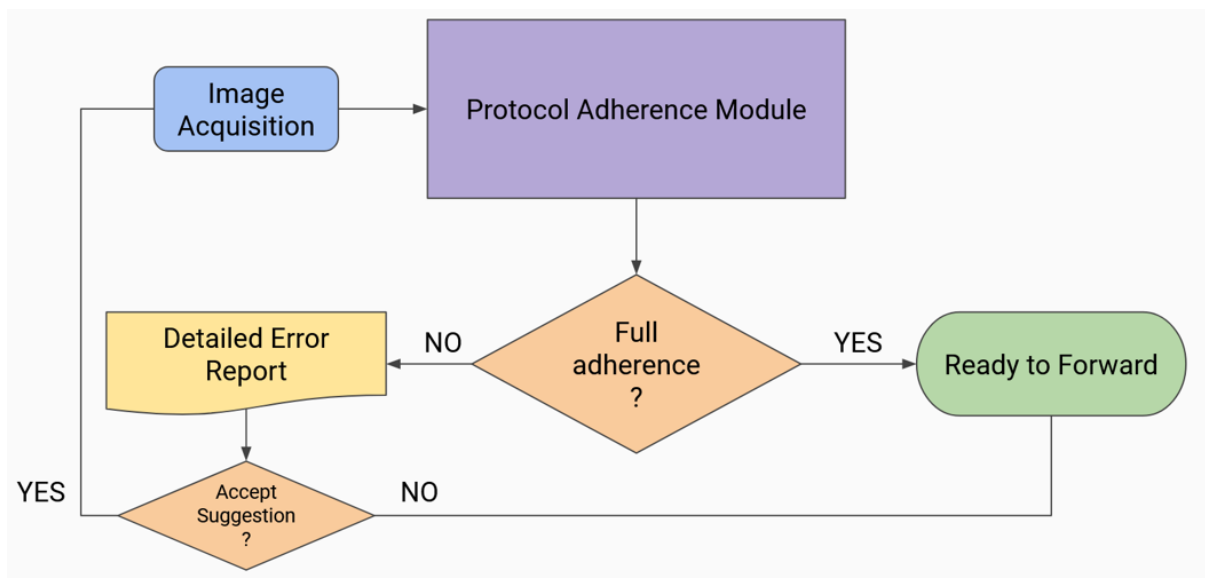
1.3.4 Metodologia

A presente pesquisa buscou aprofundar no entendimento do tema para formular hipóteses a serem testadas em estudo de caso. Nesse sentido pode-se dizer que:

Pesquisa Exploratória: Visa proporcionar maior familiaridade com o problema com vistas a torná-lo explícito ou a construir hipóteses. Envolve levantamento bibliográfico; entrevistas com pessoas que tiveram experiências práticas com o problema pesquisado; análise de exemplos que estimulem a compreensão. Assume, em geral, as formas de Pesquisa Bibliográfica e Estudos de Caso [...] realiza descrições precisas da situação e quer descobrir as relações existentes entre seus elementos [...] Recomenda-se a pesquisa exploratória quando há pouco sobre o problema a ser estudado. (CERVO; BERVIAN; SILVA, R. d., 2009).

Portanto, esta pesquisa enquadra-se como sendo de natureza aplicada e caráter exploratório.

Figura 4 – Cenário de aplicação



Fonte: Elaborado pelo autor (2023).

O método científico utilizado neste trabalho foi o hipotético-dedutivo, ou simplesmente dedutivo, proposto pelo filósofo austríaco Karl S. Popper (POPPER, 1975). O processo dedutivo de Popper envolve quatro passos:

1. Formalização do problema de modo a obter consistência e verificar contradições.
2. Levantamento de conjecturas (hipótese, teorias, etc...) para solução do problema.
3. Verificação da conjectura pela dedução das consequências na forma de proposições passíveis de teste.
4. Falseamento, provar que a teoria é científica pela tentativa de refutação através de observação e experimentação.

Se a hipótese se mostrar verdadeira, a teoria é corroborada (mas nunca verificada), por outro lado, se a hipótese não superar os testes estará falseada, necessitando nova reformulação do problema e/ou da hipótese, gerando novos problemas. (THORNTON, 2022).

De maneira análoga a esta pesquisa podemos dizer que, (i) foi realizado estudos iniciais para conhecimento e adequação do problema, (ii) geração da hipótese para solução do problema (pergunta de pesquisa), (iii) etapa de desenvolvimento para testar proposições que respondam a hipótese e por fim (iv) comprovação da pesquisa através de validação da hipótese.

1.3.5 Estrutura da Dissertação

Esta dissertação está dividida em 6 capítulos. Iniciando-se com a introdução (capítulo 1), de forma a apresentar o tema, contextualização do problema, motivação, justificativa, hipótese, objetivos, metodologia, cenário de aplicação e por último esta estrutura da dissertação. O capítulo 2 apresenta a fundamentação teórica. Os trabalhos relacionados são discutidos no capítulo 3. O capítulo 4 apresenta a definição do escopo e a abordagem metodológica para cada subproblema identificado e em sequência, os resultados são apresentados no capítulo 5. Por fim, as conclusões e discussões finais estão elaboradas no capítulo 6.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são detalhados conceitos introdutórios e fundamentos teóricos necessários para a boa compreensão desta pesquisa.

2.1 PROTOCOLOS DE AQUISIÇÃO DE IMAGENS NO STT/SC

De acordo com o manual técnico de teledermatologia no Sistema Integrado Catarinense de Telemedicina e Telessaúde (STT/SC) (WAGNER; PICOLOTTO DE LARA, 2022), a rotina de aquisição de imagens segue um dos dois protocolos para aquisição de imagens com base no tipo de hipótese diagnóstica. Tais protocolos são:

- Protocolo para Câncer de Pele
- Protocolo para Outras Dermatoses

Estes protocolos ditam os requisitos e padrões para cada tipo de captura das imagens em exames de teledermatologia no STT/SC, cada protocolo de exame pode conter dois ou mais dos seguintes protocolos de captura de imagem:

- Foto de Aproximação com Régua: fotografia de cada lesão a ser avaliada com uma régua posicionada ao lado para prover uma referência da tamanho da lesão, capturada a cerca de 30cm.
- Foto Panorâmica: fotografia corporal inteira de frente e de costas, capturada a cerca de 3m, e uma fotografia com maior contexto da região afetada capturada a cerca de 1m.
- Foto de Contato (dermatoscópica): fotografia capturada com auxílio de um dermatoscópio acoplado a câmera, com até 10x de aproximação e uso de gel ou óleo específico para dermatoscopia.

Uma visualização ampla do esquema completo dos protocolos de exame e aquisição de imagens pode ser conferida na Figura 5

2.1.1 Protocolo Câncer de Pele

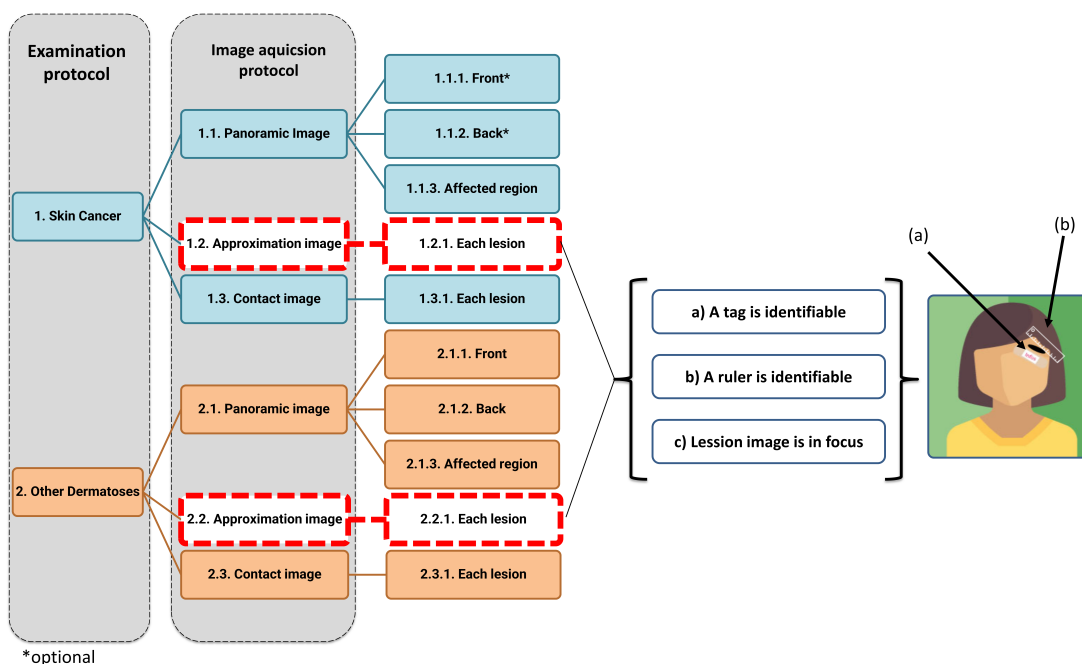
Para o protocolo de Câncer de Pele os requisitos para aquisição de imagem seguem as regras a seguir:

(i) Foto de Aproximação com Régua (Figura 6a)

Requisitos:

- Régua branca ao lado da lesão
- Etiqueta com identificação do paciente, data e número da lesão.
- Etiqueta deve estar totalmente visível.
- Marcação da régua deve estar visível.
- Lesão deve estar totalmente visível.

Figura 5 – Panorama esquemático dos protocolos de exame e aquisição de imagens na Tele dermatologia.



Fonte: Elaborado pelo autor (2023).

(ii) Foto Panorâmica (Figura 6b)

Requisitos:

- Etiqueta com identificação do paciente, data e número da lesão.
- Somente da região afetada.

(iii) Foto de Contato (Figura 6c)

Requisitos:

- Bordas do dermatoscópio não devem aparecer.
- Aplicação correta e em quantidade suficiente de gel.
- Foco correto.

2.1.2 Protocolo Outras Dermatoses


Para o protocolo Outras Dermatoses os requisitos para aquisição de imagem seguem as regras a seguir:

(i) Foto de Aproximação com Régua (Figura 6a)

Requisitos:

- Régua branca ao lado da lesão
- Etiqueta com identificação do paciente, data e número da lesão.
- Etiqueta deve estar totalmente visível.

Figura 6 – Ilustração Protocolo Câncer de Pele



(a) aproximação, (b) panorâmica e (c) foto de contato.

Fonte: Adaptado de Wagner e Picolotto de Lara (2022)

- Marcação da régua deve estar visível.
- Lesão deve estar totalmente visível.

(ii) Foto Panorâmica (Figura 1)

Requisitos:

- Etiqueta com identificação do paciente, data e número da lesão.
- Foto de corpo de frente e de costas.
- Foto da região afetada.

(iii) Foto de Contato (Figura 6c)

Requisitos:

- Bordas do dermatoscópio não devem aparecer.
- Aplicação correta e em quantidade suficiente de gel.
- Foco correto.

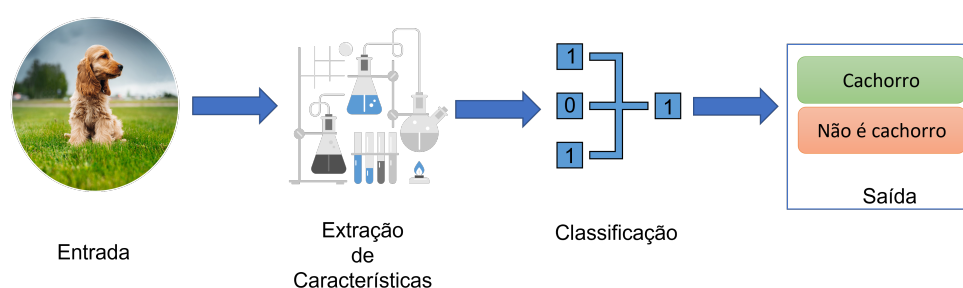
2.2 INTELIGÊNCIA ARTIFICIAL

Inteligência Artificial (IA) é o processo de transmissão de conhecimento humano às máquinas. O objetivo da Inteligência Artificial é desenvolver máquinas autossuficientes que possam pensar e agir como humanos, de forma a poder realizar tarefas aprendendo e resolvendo problemas. A maioria dos sistemas de IA simulam a inteligência natural humana para resolver problemas complexos (JAKHAR; KAUR, 2020). Dentre as diferentes maneiras de se ensinar um computador a resolver um problema de forma inteligente, atualmente, as técnicas de Aprendizado de Máquina e Aprendizado Profundo são as mais utilizadas. Seu uso está presente em quase todas as áreas da ciência. Na área da medicina em geral, técnicas de IA são amplamente utilizadas para automação e auxílio de diagnóstico em exames de imagens.

2.2.1 Aprendizado de Máquina

Aprendizado de Máquina ou *Machine Learning* (ML), é uma disciplina da ciência da computação que utiliza algoritmos e análises computacionais e estatísticas para construir modelos preditivos que podem resolver problemas do mundo real (JAKHAR; KAUR, 2020). Na visão de Samuel (2000) são algoritmos que podem aprender com dados sem depender de programação baseada em regras. É uma técnica muito utilizada para problemas de classificação. Um fluxo básico de classificação de imagem pode ser conferido na Figura 7.

Figura 7 – Fluxo base *Machine Learning* aplicado a classificação de imagem

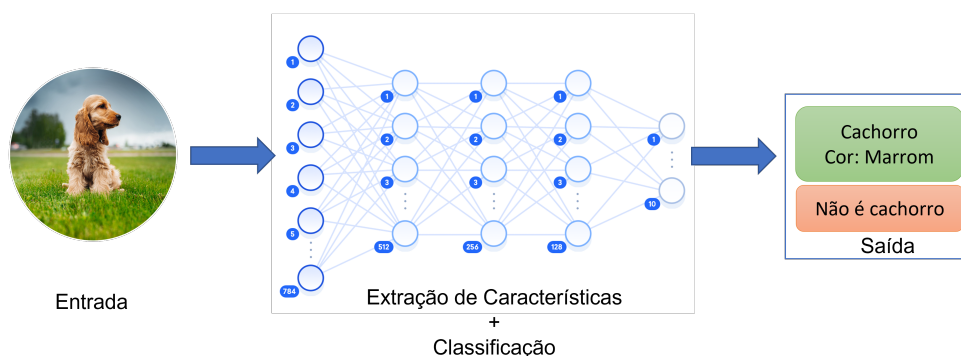


Fonte: Elaborado pelo autor (2023).

2.2.2 Aprendizado Profundo

Aprendizado Profundo ou *Deep Learning* (DL), é uma técnica de ML que faz uso de redes neurais artificiais (RNA), essas redes imitam o funcionamento do cérebro humano. Elas recebem informações e, em seguida, geram uma saída com base no conhecimento adquirido através de exemplos. Cada neurônio artificial dentro de uma rede neural é responsável por resolver uma pequena parte do problema. Eles passam o que sabem para os outros neurônios, até que todos os outros neurônios interconectados consigam resolver o problema inicial e obter uma resposta de saída (JAKHAR; KAUR, 2020; ZHANG *et al.*, 2018). A Figura 8 ilustra genericamente um exemplo de uma classificação de imagem. Os algoritmos de aprendizado profundo diferem dos algoritmos de aprendizado de máquina em sua capacidade de aprender com dados não estruturados e de maneira intuitiva, ou seja, são capazes de aprender características em um conjunto de dados mesmo sem nenhuma informação deste conjunto ter sido previamente inserida ou definida.

Atualmente DL é o campo com maior proeminência na visão computacional e análise de imagens médicas.

Figura 8 – Fluxo base *Deep Learning* aplicado a classificação de imagem

Fonte: Elaborado pelo autor (2023).

2.3 VISÃO COMPUTACIONAL


Visão Computacional (VC) é o conjunto de métodos e técnicas através dos quais sistemas computacionais podem ser capazes de interpretar imagens. Podendo ainda ser dividida em visão clássica, onde são utilizados métodos numéricos e operações de morfologia matemática, e visão computacional baseada em inteligência artificial, onde são utilizadas técnicas de aprendizado de máquina e aprendizado profundo (WANGENHEIM; COMUNELLO; RICHA, 2013). Dentre as principais tarefas de VC podemos destacar:

- **Classificação de imagens:** Busca classificar a imagem como um todo de forma a responder algum questionamento. Ex: Há um animal na imagem? A imagem é uma paisagem?
- **Detecção de Objetos:** Tentar localizar um ou mais objetos de interesse na imagem e atribuir-lhes um rótulo de classificação com sua área localizada demarcada por um *bounding box* (BB).
- **Segmentação Semântica:** Nesta técnica, busca-se associar cada pixel da imagem a uma classe predefinida, considerando múltiplos objetos da mesma classe como um único objeto.
- **Segmentação por Instância:** Esta técnica difere da segmentação semântica, pois, consegue identificar mais de um objeto de mesma classe, ou seja, aplica uma combinação de detecção de objetos e segmentação semântica para obter resultados mais precisos.

A Figura 9 ilustra a aplicação destas tarefas e a Figura 10 demonstra a diferença entre segmentação semântica e segmentação por instância.

A área de VC é a responsável pelos maiores avanços em análises computacionais de imagens médicas, principalmente com aplicações de redes neurais convolu-

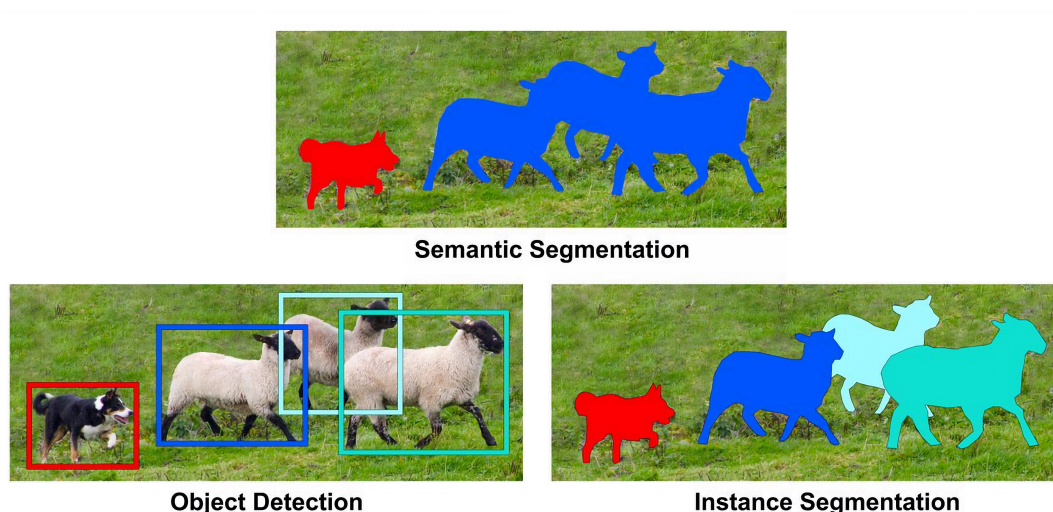
Figura 9 – Diferenças entra as principais tarefas de visão computacional.



Classificação, Detecção de Objeto e Segmentação por instância.

Fonte: Adaptado de Khan (2020, p.2)

Figura 10 – Diferenças entra os tipos de Segmentação.



Detecção de Objeto, Segmentação Semântica e Segmentação por instância.

Fonte: Adaptado de Tedrake (2022, cap.6)

cionais (CNN), que é um subtipo de DL que impulsionou grandemente os estudos de análise de imagens por reduzir o número de parâmetros de entrada e extrair automaticamente os vetores de características de uma imagem (VOULODIMOS *et al.*, 2018). Atualmente arquiteturas CNNs são aplicadas nas mais variadas análises de imagens médicas, tais como, raio-x, ressonância magnética, microscopia e principalmente em dermatologia. (PURI *et al.*, 2020; VOULODIMOS *et al.*, 2018).

2.4 HUMAN POSE ESTIMATION


Human Pose Estimation (HPE), é uma das técnicas de visão computacional que tem como objetivo identificar e localizar partes ou juntas (conexões de partes) do corpo humano em imagens ou vídeos e sua orientação. Embora possa ser aplicada a objetos

também, seu uso é mais frequente para análise corporal humana. Considerando que o movimento de um membro pode ser interpretado como uma sequência de poses, reconhecer a pose do corpo humano é fundamental para uma análise de movimento e identificação de gestos (SONG *et al.*, 2021; JOSYULA; OSTADABBAS, 2021). Nesse contexto, os algoritmos de HPE se tornam a melhor opção para problemas que envolvem identificar, analisar e descobrir orientações de partes do corpo ou de corpo inteiro. Há diversos algoritmos e modelos de HPE para análise de corpo inteiro ou partes específicas, como mãos e rosto.

De acordo com Zheng *et al.* (2020), os modelos de HPE mais utilizados são:

- **Kinematic** ou **Keypoint**, que busca identificar relações (keypoints) entre as diferentes partes do corpo. Pode ser utilizado tanto para gerar HPE em 2D ou 3D. (Figura 11a)
- **Planar**, utilizado para representar a forma e aparência do corpo humano através de estruturas retangulares para cada parte. Utilizado apenas em 2D. (Figura 11b)
- **Volumetric**, modelo utilizado para extrair uma malha 3D completa no formato do corpo ou de suas partes. (Figura 11c)

Figura 11 – Modelos de Human Pose Estimation.



Fonte: Adaptado de Zheng *et al.* (2020)

3 TRABALHOS CORRELATOS

Para a verificação de trabalhos relacionados foi realizada uma pesquisa sistemática de literatura nos padrões descritos por Kitchenham (2004) nos principais banco de dados científicos abertos que aceitam operadores booleanos na construção da frase de pesquisa. O detalhamento desta pesquisa está descrito na Seção 3.1 e a apresentação e discussão dos resultados podem ser observados respectivamente na Seção 3.2 e Seção 3.3.

A quase total ausência de resultados relevantes sugere que os estudos que envolvem Visão Computacional na teledermatologia e dermatologia estão fortemente concentrados em automação de diagnóstico. A busca também sinalizou uma possível ameaça a pesquisa, que foi descartada conforme discussão apresentada na Seção 3.4.

3.1 DEFINIÇÕES DA BUSCA

Por conta de que nossas buscas realizadas com maior enfoque terem demonstrado, primariamente, uma ausência ou resultados irrelevantes, a nossa estratégia final de pesquisa adotada visou obter o máximo de resultado possível. De modo que a fórmula da *string* de busca foi modelada a partir do tema ("teledermatology") e acrescido de uma ou todas as possíveis tecnologias aplicáveis ("*deep learning*", "*machine learning*" e "*computer vision*") tornando a pesquisa mais ampla. Similarmente, o intervalo de tempo maior (2000-2022) também serviu para analisar temporalmente as publicações de modo a verificar o crescente interesse acadêmico pela área. As informações completas das bases e limitações estão definidas na Quadro 1. Os resultados compilados por base podem ser conferidos na Seção 3.2 - Tabela 1.

O portal ACM Digital Library possui duas bases de procura, ACM-Full-Text Collection e ACM-Guide to Computing Literature, aqui definidas como ACM Digital Library FTC e ACM Digital Library GCL respectivamente. Todas as bases de busca utilizadas nesta pesquisa utilizam-se do mesmo padrão de entrada, de forma que, a *string* é geral, não sendo necessário *strings* separadas por base.

3.2 EXECUÇÃO DA BUSCA

Ao executar o protocolo definido, a busca retornou 122 resultados. Após eliminação de resultados duplicados e dos que possuíam formato diferente do definido obteve-se um total de 100 artigos passíveis de se analisar quanto aos critérios de inclusão e exclusão. Após aplicação dos critérios, restou apenas um resultado que é apresentado na Seção 3.3. O fluxo da execução pode ser visualizado na Figura 12 e a lista dos resultados excluídos com motivo podem ser verificados no Apêndice A - Tabela 7.

Quadro 1 – Definição do protocolo utilizado na busca.

Bases de Buscas

IEEE Xplore
 ScienceDirect
 ACM Digital Library
 PubMed

Crítérios de Inclusão

Artigos disponíveis integralmente nas bases selecionadas.
 Artigos publicados no período de 2000 até 2022
 Artigos publicados no idioma inglês.
 Artigos que tratam de teledermatologia.
 Artigos que tratam do modelo assíncrono de teledermatologia.
 Artigos que mencionam ao menos um tipo de controle de qualidade ou padrão de imagem na tel

Crítérios de Exclusão

Artigos não disponíveis integralmente nas bases selecionadas.
 Artigos publicados fora do período de 2000 até 2022
 Artigos publicados em outros idiomas que não o inglês.
 Artigos que não tratam de teledermatologia.
 Artigos que tratam do modelo síncrono de teledermatologia.
 Artigos que tratam de diagnóstico.
 Artigos que não mencionam controle de qualidade ou padrão de imagem em teledermatologia.

String Geral de Busca

"teledermatology" AND ("deep learning" OR "machine learning" OR "computer vision")

Fonte: Elaborado pelo autor (2022)

Tabela 1 – Compilado dos Resultados das Buscas.

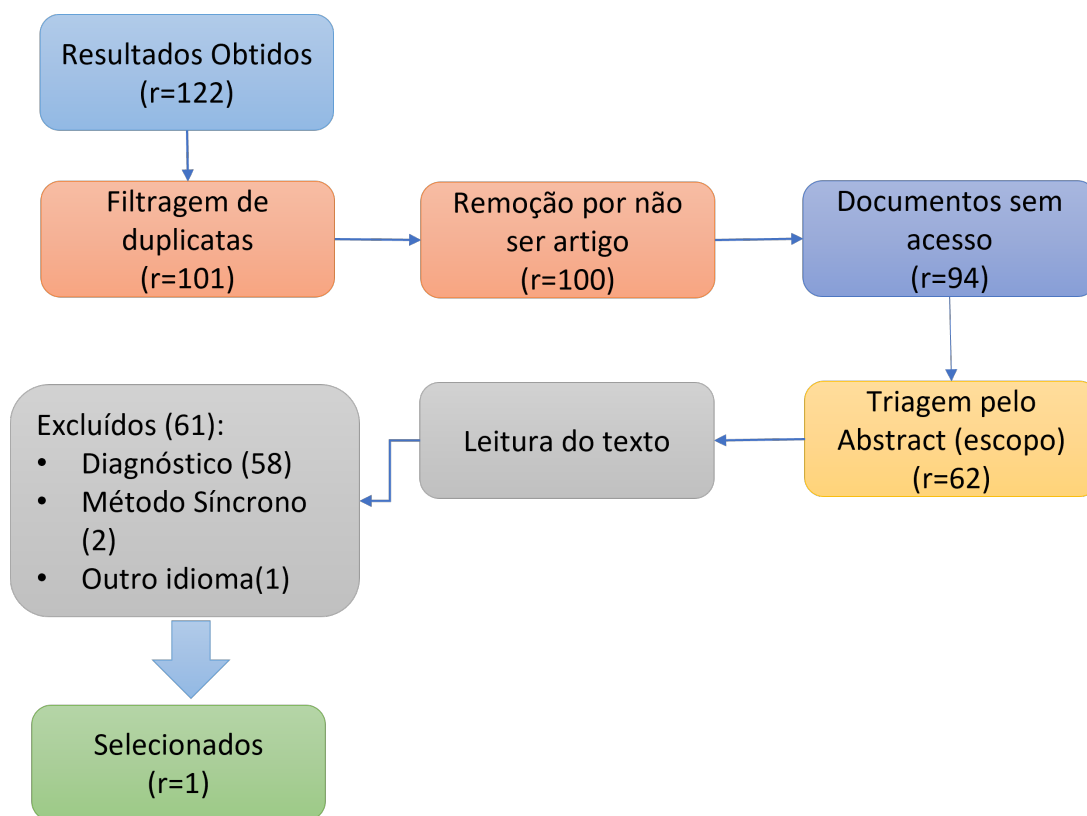
| Base | Retorno |
|-------------------------|---------|
| IEEE Xplore | 7 |
| ScienceDirect | 47 |
| ACM Digital Library GCL | 36 |
| ACM Digital Library FTC | 8 |
| PubMed | 24 |

Fonte: Elaborado pelo autor (2023)

3.3 DISCUSSÃO DOS RESULTADOS DA BUSCA

O trabalho intitulado: “*TrueImage: A Machine Learning Algorithm to Improve the Quality of Telehealth Photos*” de Vodrahalli *et al.* (2021), foi o único trabalho resultante da pesquisa. Neste trabalho os autores avaliam a qualidade da imagem antes do envio ao especialista, motivados pelo desgaste e perda de tempo em ambas as pontas

Figura 12 – Sequência de execução da revisão



Fonte: Elaborado pelo autor (2023)

(paciente e médico). Mais especificamente, os autores propõem um método para gerar um IQA (*image quality assessment*, lit. “avaliação de qualidade de imagem”) com base na iluminação, desfoque e zoom. Ao mesmo tempo, reforçam a importância da qualidade de imagens para exames teledermatológicos e a pouca existência de pesquisa na área devido ao foco em automação de diagnóstico.

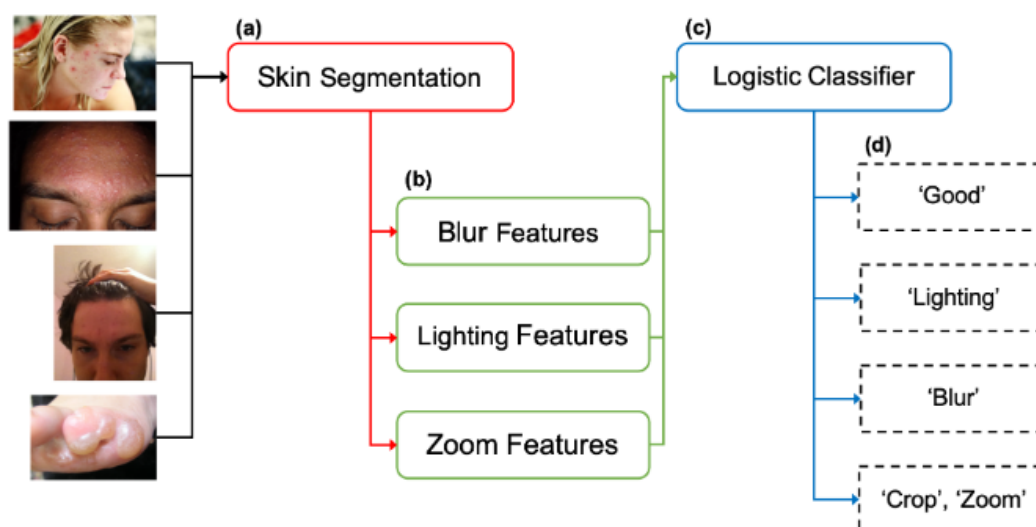
O modelo proposto faz uso de segmentação semântica para gerar as áreas de interesse da imagem (área lesionada e pele) e com essas áreas gerar características (através de técnicas de ML) para definir: desfoque, iluminação e zoom. Em seguida, essas características são reduzidas, concatenadas e inseridas cada uma em um classificador binário utilizando-se da técnica de regressão logística de forma a obter uma resposta sobre esses parâmetros individuais e um IQA na forma “good” ou “bad” (lit. “bom” ou “ruim”). Este fluxo pode ser visualizado na Figura 13.

O conjunto de dados utilizado foi rotulado manualmente por um dermatologista de forma a caracterizar a imagem como “boa” ou “ruim” e dizer um dos três motivos pelo qual seria ruim: desfoque, iluminação, zoom.

Apesar do estudo demonstrar resultados interessantes (média de 80% de confiança), o conjunto de dados utilizados é demasiadamente pequeno, fato reconhecido

pelos autores, que mesmo utilizando aumento sintético dos dados ficou com apenas 362 imagens e que posteriormente ainda foi dividido aleatoriamente em subconjuntos de treino, validação e teste (a proporção não foi divulgada). Pela forma como este conjunto depende de anotação e avaliação especialista (dermatologista) para caracterizar uma imagem apta a um diagnóstico, acaba impondo um certo grau de dificuldade para sua construção e evolução.

Figura 13 – Pipeline de execução Truelmage



Após a entrada da imagem é realizado: (a) segmentação da área de interesse, (b) geração de características, (c) são aplicados 4 classificadores nos vetores de características agrupados, (d) saída dos classificadores.

Fonte: Adaptado de Vodrahalli *et al.* (2021)

3.4 AMEAÇA A PESQUISA

O diminuto resultado da pesquisa levou a dois questionamentos:

1. Há uma necessidade?
2. Há perspectiva de futuro na teledermatologia?


Os dados divulgados do STT/SC, um sistema de teledermatologia de larga escala que já realizou mais de 130.000 exames teledermatológicos, nos diz que há uma necessidade de verificação dos padrões e qualidade das imagens teledermatológicas para redução de invalidação de exames como notado anteriormente na Figura 3. Esta necessidade também é reforçada por Vodrahalli *et al.* (2021) onde o foco do estudo foi a identificação da qualidade da imagem de forma a diminuir a necessidade de se refazer as imagens e evitar erros em diagnóstico, por fim, a afirmação de Pasquali *et al.* (2020) fortalece essa necessidade:

Uma boa imagem é o requisito mais básico para fazer um diagnóstico em tele dermatologia. Borrado/fora de foco, desequilíbrio de cores, visão insuficiente [...], posicionamento incorreto constituem algumas das limitações mais importantes que impedem o especialista de fazer o diagnóstico correto. (PASQUALI *et al.*, 2020, p.14, tradução nossa).

Quanto ao interesse e a perspectiva da tele dermatologia, os resultados temporais obtidos através do protocolo de pesquisa definido na Seção 3.1, demonstram uma tendência ao crescimento do interesse acadêmico sobre o tema nos últimos quatro anos, essa evolução temporal pode ser visualizada na Figura 14. Pasquali *et al.* (2020, p.18, tradução nossa), reforça esse interesse ao afirmar que: “TD é o futuro da prática da dermatologia.[...] representa o único caminho para atender uma população que está crescendo em número e idade.”, igualmente, para Trinh *et al.* (2022) a tele dermatologia é a solução para as limitações dos sistemas de atendimento tradicionais em virtude da dificuldade de pessoas mais idosas de se locomoverem. Já na visão de Puri *et al.* (2020), a tele dermatologia nos EUA (e similarmente outros países) teve uma adoção acelerada causada pelas restrições da pandemia da COVID-19, de forma que, para aproveitar o momento crescente, há de se incentivar as melhorias ao acesso, resultados e a experiência de uso do paciente. No aspecto econômico, a “Fortune Business Insights”, grande empresa de pesquisa de mercado, demonstrou em seu relatório de 2022 sobre o mercado da tele dermatologia¹ um crescimento de quase 4 bilhões de dólares entre os anos 2020-2021, há ainda previsão de um mercado de aproximadamente 68 bilhões de dólares até 2028. De forma que é possível afirmar que há um interesse crescente acadêmico e econômico sobre a tele dermatologia.

¹ <https://www.fortunebusinessinsights.com/infographics/tele dermatology-market-103491>

Figura 14 – Resultado da Revisão: Gráfico de Publicações por Ano



Fonte: Elaborado pelo autor. (2023)

4 PROPOSTA PARA CRÍTICA DOS PROTOCOLOS

Neste capítulo é apresentado a definição do escopo da proposta, os materiais utilizados, os métodos de processamento de imagens, as métricas e o *design* do estudo de validação.

4.1 DELIMITAÇÃO DO ESCOPO

Um critério de qualidade que também está presente em todos os protocolos de aquisição de imagens e que não abordamos neste trabalho foi o foco da imagem. A avaliação automatizada do foco fotográfico é uma tarefa muito complexa que, até a data da redação deste manuscrito, não foi resolvida de forma satisfatória, nem por métodos clássicos de visão computacional, nem por métodos baseados em aprendizagem profunda. Existem muitos métodos clássicos de visão computacional diferentes para avaliação de foco e também algumas tentativas de desenvolver métodos de avaliação de foco baseados em aprendizagem profunda. Num conjunto de experiências *ad hoc* que realizamos antes da execução formal deste estudo, determinamos que todos estes métodos produzem resultados extremamente pouco fiáveis, mesmo os métodos clássicos atualmente utilizados em equipamentos fotográficos digitais, sendo todos eles extremamente sensíveis a variações nas texturas de fundo em imagens panorâmicas e também na textura da pele e espessura do cabelo em imagens de aproximação. Fundos altamente texturizados ou pele peluda, por exemplo, induzem esses algoritmos a classificar imagens altamente desfocadas como nítidas. Já a pele com cabelos loiros muito claros ou sem pelos, quase sempre foi classificada como desfocada, mesmo que focada corretamente.

Considerando as similaridades dos tipos de imagens presentes nos protocolos apresentados na Seção 2.1, e a limitação do escopo, a abordagem de crítica foi aplicada em dois tipos possíveis de imagens de maneira independente, na forma que se segue:

- Método para crítica de imagens de aproximação com régua.
- Método para crítica de imagens panorâmicas.

4.2 MATERIAIS

Para este estudo foi utilizado um conjunto de dados composto por 36.102 exames teledermatológicos realizados no STT/SC entre janeiro/2021 e dezembro/2021. Esse conjunto de dados apresentou média de 9 imagens e 4,5 MB por exame, totalizando 1.462.131 MB (1,4 TB) para todo o conjunto de dados. A partir deste conjunto de exames, filtramos dois conjuntos de dados de imagens para serem utilizados total ou parcial neste estudo, cada subconjunto composto por 16.180 imagens é pertinente

a exames inválidos ou válidos, essa separação foi realizada com base em uma pré-seleção de imagens do conjunto de dados dermatológicos do STT/SC.

Para tanto, utilizamos a ferramenta epidemiológica GISTeamed para buscas exploratórias (INACIO *et al.*, 2016). O GISTeamed é um mecanismo de visualização e recuperação de informações e dados, integrado à infraestrutura de telemedicina do STT/SC. Ele suporta a indexação, recuperação e exibição de informações georreferenciadas em um mapa. O mecanismo de recuperação indexa dados estruturados, objetos semiestruturados e DICOM-SR (CLUNIE, 2000). Permite realizar diversas análises epidemiológicas e plotá-las em mapa online ou imagem aérea. A coleta de dados foi realizada por meio de acesso eletrônico à plataforma de Telemedicina e Telessaúde do STT/SC disponível em <<https://telemedicina.saude.sc.gov.br/rctm/>> utilizando as credenciais de login dos autores. Os dados coletados foram exportados como planilhas e utilizados para recuperação de dados para este estudo. Para selecionar exames inválidos e dividi-los em conjuntos válidos e inválidos, utilizamos os códigos de invalidação fornecidos pelos teledermatologistas (o Apêndice A contém a lista completa de códigos de invalidação). A recuperação de imagens em massa foi então realizada por meio de consultas SQL diretas ao servidor de imagens do (STT/SC). As consultas foram construídas a partir das planilhas que geramos em nossas pesquisas. Uma vez criados os subconjuntos dos quais extraímos cada categoria de imagens, a seleção dos conjuntos finais de imagens foi aleatória. Esses subconjuntos são explicados mais detalhadamente na Seção 4.2.1 e Seção 4.2.2.

4.2.1 **Dataset para identificação de etiqueta e régua**


De acordo com os requisitos para foto de aproximação com régua dos protocolos apresentados na Seção 2.1.2 e Seção 2.1.1, podemos verificar que são iguais. Portanto, a mesma solução aplica-se aos dois protocolos sem alterações. Ainda, neste contexto, o problema pode ser enquadrado como um problema de detecção e classificação, pois:

- É necessário localizar e identificar uma etiqueta
- É necessário localizar e identificar uma régua

Para tanto, foi gerado um conjunto de dados para aplicação de técnicas de segmentação por instância, visando identificar e localizar uma etiqueta e uma régua presente na imagem. Dentro do tempo limite desta pesquisa foi possível gerar um conjunto de 14.238 imagens selecionadas aleatoriamente entre os conjuntos de exames válidos e inválidos das imagens disponíveis pertinente ao protocolo de aproximação, com um total de 28.794 classes anotadas. Cada imagem foi anotada por um especialista, identificando a área de interesse e seu rótulo. O conjunto final foi então dividido em conjunto de treinamento, usado para treinar o algoritmo de aprendizado de máquina e conjuntos de validação, usados para validar o algoritmo usando métricas padrão de aprendizado

profundo. A proporção utilizada foi de 0.7/0.15/0.15 para os subconjuntos de treinamento, validação e teste, respectivamente. A Figura 15 ilustra o número de imagens distribuídas entre os subconjuntos e a distribuição dos dados rotulados é demonstrado na Tabela 2.

Figura 15 – Distribuição das imagens entre os subconjuntos para etiqueta e régua.



Fonte: Elaborado pelo autor. (2023)

Tabela 2 – Distribuição das anotações entre os subconjuntos de etiqueta e régua.

| LABEL | TRAIN | VALIDATION | TEST | TOTAL |
|-------|-------|------------|------|-------|
| Tag | 10107 | 2180 | 2178 | 14465 |
| Ruler | 10040 | 2180 | 2139 | 14329 |

Fonte: Elaborado pelo Autor (2023)

4.2.2 Dataset para imagens panorâmicas

Analisando os requisitos para foto panorâmica dos protocolos apresentados na Seção 2.1.2 e Seção 2.1.1, verifica-se que há uma pequena divergência de requisitos. No protocolo de câncer de pele não há exigência de foto de corpo inteiro, somente foto da área lesionada, cujo requisito é possuir a presença de uma etiqueta, portanto, este problema acaba por se resolver com a mesma técnica de identificação de etiqueta e régua. Desta forma, resta o protocolo Outras Dermatoses, que requer uma foto panorâmica de frente e uma de costas do corpo do paciente. Como há a necessidade

de identificar (i) corpo inteiro e (ii) sua orientação, este problema enquadra-se em identificação de pose planar. Portanto, foi aplicada técnica de *Human Pose Estimation* (HPE) para:

- Identificar a presença de um corpo
- Identificar sua orientação

O objetivo deste conjunto de dados é avaliar nossa pipeline para o protocolo panorâmico. Como usamos um conjunto de dados pré-treinado e de acesso aberto para identificação de pose, o conjunto de dados DensePose-COCO (GULER; NEVEROVA; KOKKINOS, 2018; LIN *et al.*, 2014), precisávamos de um conjunto de dados para avaliar nossa pipeline de pós-processamento. Para este conjunto de dados foi possível gerar anotações para 3.685 imagens selecionadas aleatoriamente do conjunto disponível de imagens e rotuladas em três categorias, como segue:

- a) **pfront**, um corpo identificável de frente. Há 553 imagens com este rótulo.
- b) **pback**, um corpo identificável de costas. Há 479 imagens com este rótulo.
- c) **wrong**, não há corpo identificável. Há 2653 imagens com este rótulo.

Em virtude da aleatoriedade da amostra, nota-se, portanto, que há um desbalanceamento entre as classes, tendo mais classes com imagens incorretas do que de outras classes. Este desbalanceamento não afeta o comportamento da rede, tendo em vista que a rede é pré-treinada no conjunto DensePose-COCO e este conjunto serve apenas para validação de nossa pipeline de tratamento de pose.

4.3 MÉTODOS DE PROCESSAMENTO DE IMAGEM

Para este estudo foi definido a utilização somente de métodos consolidados e estado-da-arte. Tendo como base as revisões publicadas por Voulodimos *et al.* (2018), Josyula e Ostadabbas (2021), Zheng *et al.* (2020) e Song *et al.* (2021). Os seguintes questionamentos tiveram que ser respondidos pela solução:

1. **Uma etiqueta de informação e uma régua tem que ser identificáveis:** um algoritmo deve ser capaz de avaliar se existe uma etiqueta de informação de paciente, normalmente um pedaço de esparadrapo cirúrgico, colocado no paciente e visível na imagem, e se uma régua colocada próximo a lesão para o estabelecimento de um quadro de referência para o tamanho da lesão também é visível na imagem.
2. **Um corpo de uma pessoa tem que ser identificável:** um algoritmo deve ser capaz de identificar se existe um corpo inteiro identificável na imagem e sua orientação: se está de frente ou de costas.

Os métodos elencados que respondem aos questionamentos são explicados mais detalhadamente na Seção 4.3.1 e Seção 4.3.2.

4.3.1 Identificação da etiqueta de informações da lesão e régua

Esta tarefa teve como objetivo avaliar a visibilidade da etiqueta de informação e da régua no paciente. Para tanto, construímos um conjunto de dados contendo 14238 imagens com etiquetas e régua anotadas. Deste conjunto, 9966 imagens foram utilizadas para treinamento e o restante para as etapas de validação conforme apresentado anteriormente na Seção 4.2.1. Como mecanismo de análise de imagens, empregamos redes neurais convolucionais (CNNs). As CNNs representam uma categoria recentemente desenvolvida de redes neurais artificiais (RNAs) que se mostraram muito eficazes no reconhecimento e classificação de imagens (LIU *et al.*, 2017). O nome das CNNs deriva do uso de operadores de convolução de processamento de imagens (COs), como Laplacianos, Gaussianos, etc., que são posicionados entre camadas de neurônios artificiais para transformar o sinal que é passado por um conjunto de conexões de saída de uma camada para as conexões individuais de entrada da próxima camada. As CNNs foram originalmente introduzidas por Lecun *et al.* (1998) mas só se tornaram amplamente utilizadas nos últimos anos. Nossa estratégia inicial foi verificar se as arquiteturas CNN de última geração pré-treinadas no conjunto de dados COCO-*Common Objects in Context* (LIN *et al.*, 2014) e refinadas em nosso próprio conjunto de dados eram capazes de identificar de forma confiável as etiquetas e régua em imagens de nosso conjunto de dados de teste ou se precisávamos realizar um novo treinamento a partir do zero usando apenas nosso conjunto de dados. Para tanto, foi empregado a arquitetura Mask-RCNN (HE *et al.*, 2017) desenvolvida pela Microsoft Research Asia (MSRA), que é uma arquitetura conhecida e consolidada que atinge o estado da arte em segmentação por instâncias, que é uma técnica de classificação de imagens que segmenta objetos distintos em uma imagem gerando seu contorno de máscara por classe de objeto, conforme ilustrado na Figura 10. Para reduzir o tempo de treinamento, empregamos um método de superconvergência conhecido como *One Cycle* (SMITH; TOPIN, 2019), no qual a taxa de aprendizado decai gradualmente em vez de ser fixa durante todo o tempo e o *momentum* da rede varia com a taxa de aprendizagem, evitando de maneira mais eficiente os mínimos locais. Nossas rotinas de treinamento nesta tarefa foram implementadas com o *framework* Detectron2 (WU *et al.*, 2019), um ecossistema para detecção e classificação de objetos desenvolvido pela equipe de pesquisa de IA do Facebook (FAIR).

Este método buscou responder:

- A. Há uma etiqueta de informação de lesão visível?
- B. Há uma régua visível?

4.3.2 Identificação de Pose

O objetivo desta tarefa foi avaliar a visibilidade e orientação de um corpo humano em imagens panorâmicas. Para identificar a presença de um corpo inteiro e sua direção, implementamos técnicas de estimativa de pose humana (HPE) (JOSYULA; OSTADABBAS, 2021), pois permite identificar segmentos de um corpo humano e sua posição, além de outros tipos de análise, como reconstrução esquelética e orientação espacial (SONG *et al.*, 2021). Para tanto, a arquitetura DensePose (GULER; NEVEROVA; KOKKINOS, 2018), um método de identificação de pose bem estabelecido e de última geração que aplica aprendizado de máquina ao HPE (ZHENG *et al.*, 2020), foi usada para identificar e gerar um mapa 2D UV das partes segmentadas do corpo, onde U representa o eixo horizontal e V o eixo vertical, conforme ilustra a Figura 16. Esses segmentos corporais foram então processados para extração de orientação espacial e verificação se esses segmentos formam uma área completa do corpo humano ou se faltam partes. Para esta tarefa não foi necessário produzir um conjunto de dados de treinamento, o DensePose possui pesos pré-treinados no conjunto de dados DensePose-COCO (GULER; NEVEROVA; KOKKINOS, 2018; LIN *et al.*, 2014). O conjunto de dados DensePose-COCO é um conjunto de dados reais em grande escala com correspondências imagem-superfície anotado manualmente em 50.000 imagens do conjunto COCO. Construímos apenas o conjunto de dados de validação para o nosso método de pós-processamento conforme mencionado na Seção 4.2.2. Esta tarefa procurou responder:

- A. Existe um corpo humano completo presente na imagem?
- B. Este corpo está voltado para frente ou para trás?


4.4 MÉTODOS DE AVALIAÇÃO

Para efeito de validação da nossa abordagem, os resultados obtidos neste estudo foram submetidos a dois procedimentos de avaliação e validação como descritos abaixo na Seção 4.4.1 e Seção 4.4.2

4.4.1 Validação de aprendizado de máquina tradicional

Para a avaliação do método de identificação da etiqueta e régua foram gerados dois conjuntos de validação contendo 2.136 imagens cada e para o método de imagens panorâmicas foi gerado um conjunto de validação contendo 3.692 imagens curadas. Esses conjuntos foram submetidos à predição pelos respectivos métodos para cálculo das métricas tradicionais de aprendizado de máquina. Usamos AP/mAP expresso em termos de verdadeiros positivos (TP), falsos positivos (FP) e falsos negativos (FN), como nossa métrica principal, pois é a métrica mais padrão e amplamente utilizada em desafios de detecção e classificação de objetos pela sua forte ponderação que a difere

Figura 16 – Ilustração do Modelo CSE DensePose com as partes segmentadas.



Fonte: Adaptado de Guler, Neverova e Kokkinos (2018)

de métricas simples ou médias harmônicas. Como métricas auxiliares e de análise de comportamento da rede, foi utilizado *Fscore*, *Precision*, *Recall* e Matriz de Confusão conforme necessário. O Apêndice D contém as equações e descrição matemática de todas as métricas utilizadas neste trabalho.

4.4.2 Validação humana por acordo entre avaliadores

Nesse processo de validação, um conjunto aleatório de 20 imagens foi submetido a 11 profissionais de tele dermatologia para validação e avaliação para posteriormente ser comparado com a avaliação autônoma gerada pelo método combinado proposto neste estudo. Das 20 imagens, 10 referiam-se ao método etiqueta e régua e 10 ao método panorâmico (corpo inteiro e área afetada). As questões estão descritas na Tabela 3. Como este acordo entre avaliadores (IRA) possui mais de 2 (dois) avaliadores o cálculo da taxa de concordância (AR) segue o coeficiente *alpha* nominal de Krippendorff (2019) que tem sua escala variando de -1 a 1.

O resultado *alpha* pode ser interpretado da seguinte forma:

- $\alpha < 0$: os avaliadores discordam sistematicamente. Não há nenhuma confiabilidade no estudo.
- $\alpha = 0$: discordância total entre os avaliadores. Refutação do estudo.
- $\alpha = 1$: concordância unânime entre os avaliadores. Confirmação plena do estudo.

Krippendorff (2019, p.241) afirma que um $\alpha \geq 0,67$ é o limite mais baixo para consi-

derar uma medida de concordância e um $\alpha \geq 0,80$ é a taxa padrão para considerar concordância.

Tabela 3 – Questões do acordo entre avaliadores.

| Pergunta | Possibilidade de Resposta |
|--|---------------------------|
| “Há uma ETIQUETA e uma RÉGUA visível na imagem?” | SIM ou NÃO |
| “Há um corpo humano inteiro de FRENTE visível na imagem?” | SIM ou NÃO |
| “Há um corpo humano inteiro de COSTAS visível na imagem?” | SIM ou NÃO |
| “É possível visualizar UMA ou mais ETIQUETAS indicando a lesão na imagem?” | SIM ou NÃO |

Fonte: Elaborado pelo autor (2023)

5 RESULTADOS

Nesta seção é apresentado um resumo dos resultados obtidos através dos experimentos e suas respectivas métricas de avaliação.

5.1 FOTO DE APROXIMAÇÃO COM RÉGUA

Este experimento apresentou resultados muito promissores, como pode ser observado na Tabela 4. Os altos níveis da métrica mAP indicam que este método é extremamente adequado para a tarefa em questão, com grande acurácia. Os resultados são expressivos porque normalmente um $mAP \geq 70\%$ já é geralmente considerado prático para tarefas de detecção e classificação de objetos, porém, mesmo com um limiar apertado de 0.75 o mAP permaneceu acima de 75% em ambos os conjuntos. Além disso, a proximidade das métrica de avaliação nos dois conjuntos de dados de validação demonstra que este método para o nosso estudo de caso tem pouca flutuação, o que o torna confiável e robusto. A Figura 17 ilustra essa robustez devido ao conjunto de imagens possuir muitas características distintas de um mesmo objeto, de maneira que em (a) apesar de ter sobreposição de uma régua transparente sobre a etiqueta e o paciente possuir volume de pelos que altera a composição da cor da régua, os objetos de interesse foram identificados e seccionados corretamente. O mesmo resultado se repete em (b) onde há uma etiqueta sobreposta por uma régua transparente de cor verde, em (c) com uma etiqueta de material e cor diferente e uma régua maleável de silicone com muita transparência e em (d) onde destaca-se uma régua de cor sólida preta.


Tabela 4 – Métricas mAP (padrão) e mAP com limiar de 0.75 nos conjuntos de validação e teste.

| Dataset | mAP | mAP (t=0.75) |
|----------------|------------|---------------------|
| Validação | 96.06 | 76.60 |
| Teste | 95.23 | 75.52 |

Fonte: Elaborado pelo autor (2023).

No geral, este experimento determinou que para a tarefa de identificação de etiqueta e régua em uma imagem no contexto da teledermatologia, uma RCNN estado da arte, como a Mask-RCNN, apesar da grande quantidade de variação de cores e formatos de um objeto da mesma categoria, é capaz de atingir coeficiente de alta precisão (mAP acima de 90%), o que a torna extremamente adequada para esta aplicação, pois demonstrou alta capacidade de generalização mesmo com limiares altos.

Figura 17 – Exemplo visual de resultados do método de aproximação detectando diferentes tipos de régua e etiquetas



(a) sobreposição de etiqueta com régua transparente, (b) sobreposição de etiqueta com régua colorida transparente, (c) régua maleável de silicone transparente, (d) régua de cor sólida preta.

Fonte: Elaborado pelo autor (2023)

5.2 FOTO PANORÂMICA

Os resultados do pipeline do método panorâmico conforme observado na Tabela 5 e Tabela 6, demonstrou alguns fatores interessantes e levantou algumas questões. O resultado obtido no conjunto padrão de validação ficou um pouco abaixo do que é considerado um valor aplicável (70%), este resultado nos levou a investigar mais a fundo este conjunto de dados específico e por fim, descobrimos que muitas imagens corporais estão invertidas ou em modo paisagem (corpo na horizontal). Isso ocorre porque não existe um padrão de orientação da imagem durante a captura pelo pessoal responsável pela aquisição da imagem na UBS, resultando em uma mistura de imagens em modo retrato e paisagem dos pacientes. Para testar esta hipótese, um segundo conjunto de dados foi gerado girando em 90 graus todas as imagens que tinham largura maior que a altura, na tentativa de forçar uma orientação padrão sem considerar o conteúdo da imagem, também foi realizado a aplicação de métricas auxiliares para entender o comportamento. Este segundo conjunto de dados melhorou o resultado do primeiro em quase 10% no mAP e também houve melhora nas métricas mais relaxadas como o Fscore que apesar de já ter uma pontuação mais elevada no conjunto padrão, subiu 5% com o conjunto rotacionado, confirmando 2 fatos: (a) Há uma quantidade significativa de mistura de orientação de imagem em nossos dados e (b) o Densepose pré-treinado para identificar e mapear um corpo humano em pé tem dificuldade com imagens corporais que estejam em posições horizontais (paisagem) ou totalmente invertidas (de cabeça para baixo). A Figura 20 ilustra o que ocorre com uma orientação incorreta, percebe-se que a segmentação corporal é efetuada corre-

tamente, porém, a segmentação e identificação da localização dos membros sofre confusão, fato destacado na referida imagem pelo círculo vermelho que identifica as mãos, onde ambas estão sendo identificadas na mesma região, esta mesma imagem quando rotacionada corretamente apresenta resultado adequado como demonstra a Figura 19a. A matriz apresentada na Figura 18 reforça esses fatos, de modo que, é perceptível que há uma deficiência na geração dos membros segmentados do corpo com essa mistura de orientações fotográficas, tendo em vista que houve confusão significativa justamente na classificação de imagens de corpo de frente e de costas, onde muitas imagens foram classificadas como ausência das membros que determinam a existência do corpo na imagem (classe *wrong* na matriz), a rotação do *dataset* suavizou um pouco essas confusões e houve um aumento significativo de detecção dos pacientes que antes não tinham sido detectados (Classe ND na matriz). As métricas auxiliares por classe podem ser conferidas no Apêndice E. A Figura 19 ilustra uma simulação completa do método com identificação do corpo de frente (a), de costas (b) e das etiquetas na imagem aproximada de contexto (c).

Tabela 5 – Métricas mAP (padrão) e mAP com limiar de 0.75 no método de imagens panorâmicas

| Dataset | mAP | mAP (t=0.75) |
|--------------------|------------|---------------------|
| Panoramic | 66.25 | 64.01 |
| Panoramic Rotated | 75.56 | 69.25 |
| DensePose Box Ref. | 88.10 | 67.34 |

Fonte: Elaborado pelo autor (2023).


Tabela 6 – Métricas auxiliares: FScore, Precision e Recall para o método de imagens panorâmicas

| Dataset | Fscore | Precision | Recall |
|-------------------|---------------|------------------|---------------|
| Panoramic | 72.06 | 71.41 | 78.23 |
| Panoramic Rotated | 77.42 | 74.44 | 86.41 |

Fonte: Elaborado pelo autor (2023).

Em comparação com as métricas de referência DensePose, é possível observar que este modelo aplicado em nosso estudo específico pode ser bastante robusto, apresentando pouca perda entre o limiar padrão e um limiar apertado. No caso do conjunto de dados rotacionado, o limiar mais alto excedeu a base do DensePose e o conjunto de dados panorâmico padrão teve uma queda inferior a 2% com um limiar mais restrito. Além disso, conforme demonstrado através do uso do conjunto de dados rotacionado, um simples pré-processamento para identificar e girar imagens que estão

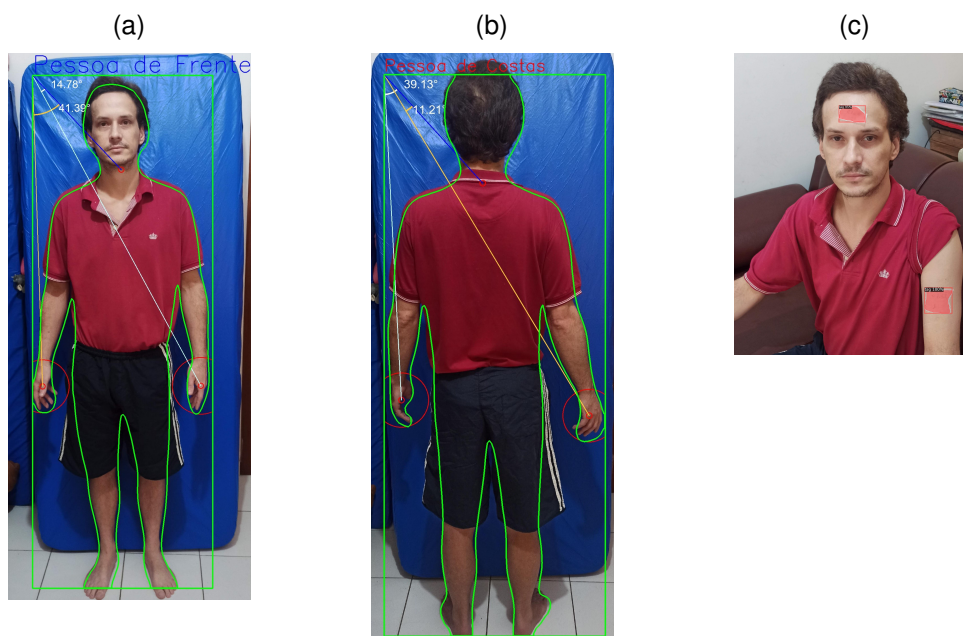
Figura 18 – Matrizes de confusão para o método de imagens panorâmicas.



(a) *Dataset Padrão*, (b) *Dataset Rotacionado*

Fonte: Elaborado pelo autor (2023).

Figura 19 – Exemplo visual simulado do resultado no método para imagens panorâmicas



(a) corpo de frente identificado corretamente, (b) corpo de costas identificado corretamente, (c) foto aproximada de contexto com identificação correta das etiquetas.

Fonte: Elaborado pelo autor (2023)

Figura 20 – Exemplo visual simulado em que houve confusão no método para imagens panorâmicas



Fonte: Elaborado pelo autor (2023)

em modo paisagens de maneira a impor um padrão, pode alcançar bons resultados. Fica evidente que uma eventual definição de padrão de orientação para captura de fotos nos protocolos durante a aquisição de imagens deve melhorar a qualidade dessa avaliação automatizada do protocolo de imagens panorâmicas.

5.3 CONCORDÂNCIA ENTRE AVALIADORES

O objetivo do estudo de validação de concordância entre avaliadores (IRA) foi de validar as avaliações de adesão ao protocolo de imagem geradas com aprendizado de máquina por um grupo de especialistas humanos. Realizamos isso calculando a taxa de concordância (AR) entre as respostas dos 11 avaliadores profissionais humanos, conforme descrito na Seção 4.4.2, e as respostas da máquina fornecidas por nossos algoritmos combinados. Este acordo atingiu um AR de **0.9668**, que é uma taxa de concordância quase perfeita. Este resultado demonstra que a combinação dos métodos discutidos neste estudo tem potencial para produzir bons resultados na tarefa de detectar aplicação inadequada dos protocolos de aquisição de imagens, e é altamente equivalente à avaliação humana da adesão aos protocolos dos exames. A matriz inter-avaliadores completa pode ser vista no Apêndice C - Tabela 8.

6 CONSIDERAÇÕES FINAIS

6.1 CONCLUSÃO

Neste estudo, nosso objetivo foi verificar a viabilidade de avaliar automaticamente a adesão dos exames de tele dermatologia aos seus protocolos de aquisição de imagens utilizando algoritmos baseados em aprendizado de máquina. Neste contexto, como principal contribuição, mostramos que a utilização de tais métodos para verificar a correta aplicação de protocolos em imagens tele dermatológicas é possível e tem grande potencial para reduzir a taxa de exames inválidos por erros de protocolo, proporcionando *feedback* automático imediato. Para tanto, empregamos modelos de Aprendizado de Máquina baseados em Redes Neurais Convolucionais para a tarefa de segmentação por instâncias e identificação de pose. Para identificar a presença de etiqueta e régua de identificação da lesão visíveis no protocolo de imagem de aproximação, empregamos a arquitetura Mask-RCNN, que mostrou resultados alcançando uma Média AP (mAP) de 95% e 96% em nossos dois conjuntos de dados de validação. Esses números são altos o suficiente para apoiar o uso da Mask-RCNN não apenas em nosso estudo de caso, mas também em outras tarefas relacionadas onde a identificação de um objeto na imagem é necessária para fornecer *feedback* adequado e avaliação de critérios. Por outro lado, para as imagens panorâmicas, empregamos Densepose, uma arquitetura de estimativa de pose humana com capacidade de gerar múltiplas análises de pose, juntamente com nossa pipeline de pós-processamento. Nossos primeiros resultados de 66% em mAP ficaram inicialmente marginalmente abaixo da taxa aceitável para aplicações práticas, mas após verificar o motivo desse comportamento e impor um padrão de orientação de imagem no conjunto de dados, melhoramos esse resultado para 75%, o que mostra que neste caso, o resultado pode ser melhorado por: a) implementação de um padrão de orientação de imagem na aquisição de imagem ou b) construindo um novo conjunto de dados de pose que inclua diferentes orientações de imagem do objeto alvo. Com os resultados deste experimento, podemos concluir que a Estimativa de Pose Humana é um método adequado para tarefas que necessitam de identificação e análise de um corpo inteiro, mas podem exigir mais pré-processamento ou uma melhor padronização das imagens para atingir todo o seu potencial. Este experimento também demonstrou a importância de se ter um padrão no processo de aquisição de imagens. Olhando para ambas as abordagens como um todo, o índice de concordância de 96.68% no IRA coloca esta abordagem combinada muito próxima de uma avaliação humana especializada. O que reforça o potencial que este estudo tem em prover *feedback* adequado e potencialmente reduzir a taxa de exames inválidos devido ao uso errôneo de protocolos de aquisição de imagens no STT/SC.

É válido ressaltar também que os métodos discutidos neste estudo podem be-

neficiar sistemas de diagnóstico automatizados, uma vez que imagens adquiridas fora do padrão esperado podem levar uma abordagem de aprendizado de máquina a um diagnóstico errôneo. Mostramos também que embora o uso de métodos de aprendizado de máquina esteja atualmente focado na automação diagnóstica, ele pode ser utilizado para melhoria no processo de triagem e conformidade de imagens. Estes resultados são promissores na tarefa de automatizar a análise do protocolo de aquisição de imagens e o processo de triagem na teledermatologia. Além disso, os métodos expostos neste estudo podem ser generalizados para triagem em outras áreas relacionadas da telemedicina, demonstrando que é possível aplicar técnicas de aprendizado de máquina fora do contexto da automação diagnóstica em teledermatologia e telemedicina com potencial para descobertas interessantes e relevantes.

O objetivo nesta pesquisa foi de proceder passo a passo definindo conjuntos mínimos de critérios de qualidade e conteúdo de imagem que podem ser avaliados automaticamente em cada protocolo de aquisição, mapeando métodos de processamento de imagem para cada um desses critérios e analisando a viabilidade do processamento de imagens geradas por cada protocolo de modo a implementar e testar diferentes soluções, neste contexto esta pesquisa apresentou pleno sucesso. É válido ressaltar que um aspecto muito importante do trabalho, foi demonstrar a possibilidade de reduzir a quantidade de exames incorretos que foram invalidados manualmente, mesmo que não os eliminando completamente.

A presente dissertação foi publicada em formato de artigo no periódico "*Telemedicine journal and e-health : the official journal of the American Telemedicine Association*", sob o registro DOI de número **10.1089/tmj.2023.0155**.

6.2 TRABALHOS FUTUROS

Um processo automatizado de avaliação de imagens só será realmente útil se for capaz de identificar e filtrar o máximo de erros possível. Como mencionado na definição do escopo (Seção 4.1), a análise do foco não foi abordada neste estudo de maneira profunda. Isso significa que, no contexto da teledermatologia no STT/SC e análises de qualidade de imagem em geral, há uma janela de continuidade desta pesquisa tendo como alvo a avaliação automatizada do foco das imagens dermatológicas, para imagens de aproximação e panorâmicas e também para imagens de contato. Diferentemente dos experimentos descritos neste trabalho, onde foram adaptado métodos de visão computacional de última geração e amplamente aceitos, para fins de avaliação automática do foco há de se realizar pesquisas de cunho básicas e teóricas e eventualmente desenvolver novos métodos de visão computacional que possivelmente combinem métodos clássicos com métodos baseados em inteligência artificial.

6.3 ÉTICA E DISPONIBILIDADE DOS DADOS

Este estudo foi aprovado pelo comitê de ética da UFSC (parecer nº 5.183.897) e os pacientes envolvidos assinaram um termo de consentimento. O estudo foi realizado como parte das atividades regulares de pesquisa e desenvolvimento do Sistema Integrado de Telemedicina e Telessaúde do Estado de Santa Catarina (STT/SC) e, portanto, recebeu apoio implícito do Governo do Estado de Santa Catarina. Como o conjunto de dados empregado neste estudo contém muitas imagens de corpo inteiro de pacientes e outras imagens onde a identidade dos pacientes poderia ser determinada e, assim, causar extremo desconforto a esses pacientes, infelizmente o conjunto de dados não pode ser disponibilizado publicamente em conjunto com esta dissertação.

REFERÊNCIAS

CERVO, Amado Luiz; BERVIAN, Pedro Alcino; SILVA, Roberto da. **Metodologia Científica**. [S.l.]: Pearson Prentice Hall, 2009.

CHAN, Stephanie; REDDY, Vidhatha; MYERS, Bridget; THIBODEAUX, Quinn; BROWNSTONE, Nicholas; LIAO, Wilson. Machine Learning in Dermatology: Current Applications, Opportunities, and Limitations. **Dermatology and Therapy**, v. 10, n. 3, p. 365–386, abr. 2020. Publisher: Springer Science and Business Media LLC.

CLUNIE, David A. **DICOM structured reporting**. [S.l.]: PixelMed Publishing, 2000. ISBN 978-0-9701369-0-9.

GOMOLIN, Arieh; NETCHIPOROUK, Elena; GNIADOCKI, Robert; LITVINOV, Ivan V. Artificial Intelligence Applications in Dermatology: Where Do We Stand? **Frontiers in Medicine**, v. 7, mar. 2020. Publisher: Frontiers Media SA.

GULER, Riza Alp; NEVEROVA, Natalia; KOKKINOS, Iasonas. DensePose: Dense Human Pose Estimation in the Wild. *In*: 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. [S.l.]: IEEE, jun. 2018.

HE, Kaiming; GKIOXARI, Georgia; DOLLAR, Piotr; GIRSHICK, Ross. Mask R-CNN. *In*: 2017 IEEE INTERNATIONAL CONFERENCE ON COMPUTER VISION (ICCV). **2017 IEEE International Conference on Computer Vision (ICCV)**. Venice, Italy: IEEE, out. 2017.

HIGH, Whitney; HOUSTON, Margaret; CALOBRISI, Stella; DRAGE, Lisa; MCEVOY, Marian. Assessment of the accuracy of low-cost store-and-forward teledermatology consultation. **Journal of the American Academy of Dermatology**, v. 42, p. 776–83, mai. 2000.

INACIO, Andrei de Souza; ANDRADE, Rafael; WANGENHEIM, Aldo von; MACEDO, Douglas D. J. Designing an information retrieval system for the STT/SC. *In*: 2014 IEEE 16th International Conference on e-Health Networking, Applications and Services (Healthcom). [S.l.]: IEEE, out. 2014.

INACIO, Andrei de Souza; SAVARIS, Alexandre; ALVES, Joao Marcus; WANGENHEIM, Aldo von. GISTelemed: An online-based GIS approach to epidemiological analysis in telemedicine systems. *In*: 2016 38th Annual International

Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). [S.l.]: IEEE, ago. 2016.

INCA. **Estimate | 2023 - Cancer Incidence in Brazil**. Rio de Janeiro: Instituto Nacional de Câncer (Brasil), fev. 2023. ISBN 978-6-5885-1710-9.

JAKHAR, D.; KAUR, I. Artificial intelligence, machine learning and deep learning: definitions and differences. **Clinical and Experimental Dermatology**, v. 45, n. 1, p. 131–132, 2020. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1111/ced.14029>.

JOSYULA, Rohit; OSTADABBAS, Sarah. **A Review on Human Pose Estimation**. [S.l.]: arXiv, 2021. Disponível em: <https://arxiv.org/abs/2110.06877>.

KHAN, Asharul. Machine Learning in Computer Vision. **Procedia Computer Science**, v. 167, abr. 2020.

KITCHENHAM, Barbara. Procedures for Performing Systematic Reviews. **Keele, UK, Keele Univ.**, v. 33, ago. 2004.

KRIPPENDORFF, Klaus. **Content analysis: an introduction to its methodology**. 4. ed. Thousand Oaks, CA: SAGE Publications, 2019. ISBN 978-1-4129-8315-0.

LANDOW, Shoshana; MATEUS, Ashley; KORGAVKAR, Kaveri; NIGHTINGALE, Deborah; WEINSTOCK, Martin. Teledermatology: Key factors associated with reducing face-to-face dermatology visits. **Journal of the American Academy of Dermatology**, v. 71, abr. 2014.

LASIERRA, N; ALESANCO, Alvaro; GILABERTE, Yolanda; MAGALLÓN-BOTAYA, Rosa; GARCÍA, Jose. Lessons learned after a three-year store and forward teledermatology experience using internet: Strengths and limitations. **International journal of medical informatics**, v. 81, p. 332–43, mar. 2012.

LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, v. 86, n. 11, p. 2278–2324, 1998. Publisher: Institute of Electrical and Electronics Engineers (IEEE).

LEVIN, Yakir; WARSHAW, Erin. Teledermatology: A Review of Reliability and Accuracy of Diagnosis and Management. **Dermatologic clinics**, v. 27, p. 163–76, vii, mai. 2009.

LIN, Tsung-Yi; MAIRE, Michael; BELONGIE, Serge; HAYS, James; PERONA, Pietro; RAMANAN, Deva; DOLLÁR, Piotr; ZITNICK, C. Lawrence. Microsoft COCO: Common Objects in Context. *In*: FLEET, David; PAJDLA, Tomas; SCHIELE, Bernt; TUYTELAARS, Tinne (Ed.). **Computer Vision – ECCV 2014**. Cham: Springer International Publishing, 2014. v. 8693. P. 740–755. ISBN 978-3-319-10601-4.

LIU, Weibo; WANG, Zidong; LIU, Xiaohui; ZENG, Nianyin; LIU, Yurong; ALSAADI, Fuad E. A survey of deep neural network architectures and their applications. **Neurocomputing**, v. 234, p. 11–26, abr. 2017. Publisher: Elsevier BV.

MAIA, Rafael; WANGENHEIM, Aldo von; NOBRE, Luiz. A Statewide Telemedicine Network for Public Health in Brazil. *In*: v. 2006, p. 495–500.

MCKOY, Karen *et al.* Practice Guidelines for Teledermatology. **Telemedicine and e-Health**, v. 22, set. 2016.

NAVARRETE-DECHENT, Cristian; DUSZA, Stephen W.; LIOPYRIS, Konstantinos; MARGHOOB, Ashfaq A.; HALPERN, Allan C.; MARCHETTI, Michael A. Automated Dermatological Diagnosis: Hype or Reality? **Journal of Investigative Dermatology**, v. 138, n. 10, p. 2277–2279, out. 2018. Publisher: Elsevier BV.

PAI, Varadraj Vasant; PAI, Rohini Bhat. Artificial intelligence in dermatology and healthcare: An overview. **Indian Journal of Dermatology, Venereology and Leprology**, v. 0, p. 1–11, mai. 2021. Publisher: Scientific Scholar.

PASQUALI, Paola; SONTHALIA, Sidharth; MORENO-RAMIREZ, David; SHARMA, Pooram; AGRAWAL, Mahima; GUPTA, Somesh; KUMAR, Dinesh; ARORA, Dharmendra. Teledermatology and its Current Perspective. eng. **Indian Dermatology Online Journal**, v. 11, n. 1, p. 12–20, fev. 2020. ISSN 2229-5178.

POMPL, R.; BUNK, W.; HORSCH, A.; STOLZ, W.; ABMAYR, W.; BRAUER, W.; GLÄSSL, A.; MORFILL, G. MELDOQ: Ein System zur Unterstützung der Früherkennung des malignen Melanoms durch digitale Bildverarbeitung. *In*: INFORMATIK aktuell. [S.l.]: Springer Berlin Heidelberg, 2000. P. 234–238.

POMPL, R. *et al.* Charakterisierung der Farbeigenschaften melanozytärer Hautveränderungen zur Unterstützung der Früherkennung des malignen Melanoms. *In*: INFORMATIK aktuell. [S.l.]: Springer Berlin Heidelberg, 1999. P. 160–164.

POPPER, Karl. S. **A lógica da pesquisa científica**. 2. ed. [S.l.]: Cultrix, 1975.

PURI, Pranav; YIANNIAS, James A.; MANGOLD, Aaron R.; SWANSON, David L.; PITTELKOW, Mark R. The policy dimensions, regulatory landscape, and market characteristics of teledermatology in the United States. en. **JAAD International**, v. 1, n. 2, p. 202–207, dez. 2020. ISSN 2666-3287.

ROMERO, Guillermo; GARRIDO, J.A.; GARCIA-ARPA, Mónica. Telemedicine and Teledermatology (I): Concepts and Applications. **Actas dermo-sifiliográficas**, v. 99, p. 506–22, out. 2008.

SAMUEL, A. L. Some studies in machine learning using the game of checkers. **IBM Journal of Research and Development**, v. 44, n. 1.2, p. 206–226, 2000.

SILVA, Cristiana; SOUZA, Murilo; DUQUE, Isabelle; MEDEIROS, Luciana; MELO, Nayra; ARAÚJO, Cecília; CRIADO, Paulo. Teledermatologia: correlação diagnóstica em serviço primário de saúde. **Anais Brasileiros De Dermatologia - AN BRASIL DERMATOL**, v. 84, out. 2009.

SMITH, Leslie N.; TOPIN, Nicholay. Super-convergence: very fast training of neural networks using large learning rates. *In*: ARTIFICIAL INTELLIGENCE AND MACHINE LEARNING FOR MULTI-DOMAIN OPERATIONS APPLICATIONS. **Artificial Intelligence and Machine Learning for Multi-Domain Operations Applications**. Edição: Tien Pham. Baltimore, United States: SPIE, 10 mai. 2019. P. 36.

SONG, Liangchen; YU, Gang; YUAN, Junsong; LIU, Zicheng. Human pose estimation and its application to action recognition: A survey. **Journal of Visual Communication and Image Representation**, v. 76, p. 103055, abr. 2021.

TEDRAKE, Russ. **Robotic Manipulation: Perception, Planning, and Control**. [S.l.]: Course Notes for MIT 6.4210, 2022.

THOMSEN, Kenneth; IVERSEN, Lars; TITLESTAD, Therese Louise; WINTHER, Ole. Systematic review of machine learning for diagnosis and prognosis in dermatology. **Journal of Dermatological Treatment**, v. 31, n. 5, p. 496–510, out. 2019. Publisher: Informa UK Limited.

THORNTON, Stephen. **Karl Popper**. Edição: Edward N. Zalta e Uri Nodelman. Fall 2022. [S.l.]: Metaphysics Research Lab, Stanford University, 2022.

<https://plato.stanford.edu/archives/fall2022/entries/popper/>.

TRINH, Pavin; YEKRANG, Kiana; PHUNG, Michelle; PUGLIESE, Silvina; CHANG, Anne Lynn S.; BAILEY, Elizabeth E.; KO, Justin M.; SARIN, Kavita Y. Partnering with a senior living community to optimise teledermatology via full body skin screening during the COVID-19 pandemic: A pilot programme. *eng*, e141, jun. 2022. ISSN 2690-442X.

VODRAHALLI, Kailas; DANESHJOU, Roxana; NOVOA, Roberto A.; CHIOU, Albert; KO, Justin M.; ZOU, James. Truelmage: A Machine Learning Algorithm to Improve the Quality of Telehealth Photos. *eng*. **Pacific Symposium on Biocomputing. Pacific Symposium on Biocomputing**, v. 26, p. 220–231, 2021. ISSN 2335-6936.

VOULODIMOS, Athanasios; DOULAMIS, Nikolaos; DOULAMIS, Anastasios; PROTOPAPADAKIS, Eftychios. Deep Learning for Computer Vision: A Brief Review. **Comput Intell Neurosci**, v. 2018, p. 7068349, 2018.

WAGNER, Harley Miguel; PICOLOTTO DE LARA, Mylena. **Manual Teledermatologia: Técnico**. [S.l.: s.n.], jan. 2022. Acesso em: 3 out. 2023.

WANGENHEIM, Aldo von; COMUNELLO, Eros; RICHA, Rogério. **Visão computacional: Seminário Introdução à Visão computacional. The Cyclops Project. PPGCC-INE-UFSC**. 2013. Disponível em:

<https://www.inf.ufsc.br/~aldo.vw/visao/>. Acesso em: 7 out. 2021.

WANGENHEIM, Aldo von; NUNES, Daniel Holthausen. Creating a Web Infrastructure for the Support of Clinical Protocols and Clinical Management: An Example in Teledermatology. **Telemedicine and e-Health**, v. 25, p. 781–790, nov. 2018.

WANGENHEIM, Aldo von; NUNES, Daniel Holthausen. Direct Impact on Costs of the Teledermatology-Centered Patient Triage in the State of Santa Catarina - Analysis of the 2014-2018 Data. **INCoD/UFSC**, TELEMED.04.2018.E.01 jul. 2018. ISSN 2236–5281.

WANGENHEIM, Aldo von; NUNES, Daniel Holthausen; WAGNER, Harley Miguel. **TELEDERMATOLOGIA – Manual – Protocolo do Registro Fotográfico da Teledermatologia. INCoD-Telemed-TR009.2019.p**, 2019.

WU, Yuxin; KIRILLOV, Alexander; MASSA, Francisco; LO, Wan-Yen; GIRSHICK, Ross. **Detectron2**. 2019. Disponível em:

<https://github.com/facebookresearch/detectron2>. Acesso em: 9 out. 2023.

ZHANG, W.J.; YANG, Guosheng; LIN, Yingzi; JI, Chunli; GUPTA, Madan. On Definition of Deep Learning. *In*: p. 1–5.

ZHENG, Ce; WU, Wenhan; CHEN, Chen; YANG, Taojiannan; ZHU, Sijie; SHEN, Ju; KEHTARNAVAZ, Nasser; SHAH, Mubarak. **Deep Learning-Based Human Pose Estimation: A Survey**. [S.l.]: arXiv, 2020. Disponível em:

<https://arxiv.org/abs/2012.13392>.

APÊNDICE A – LISTA DE ARTIGOS COM MOTIVOS DE EXCLUSÃO

Tabela 7 – Relatório Artigos Excluídos

| Titulo | Motivo |
|---|----------------|
| A benchmark for neural network robustness in skin cancer classification | Diagnóstico |
| A coarse-to-fine approach for segmenting melanocytic skin lesions in standard camera images | Diagnóstico |
| A Computer-Aided Decision Support System for Detection and Localization of Cutaneous Vasculature in Dermoscopy Images Via Deep Feature Learning | Diagnóstico |
| A Computer-Aided Diagnosis System Using Deep Learning for Multiclass Skin Lesion Classification | Diagnóstico |
| A deep learning system for differential diagnosis of skin diseases | Diagnóstico |
| A new color assessment methodology using cluster-based features for skin lesion analysis | Diagnóstico |
| A new deep learning approach integrated with clinical data for the dermoscopic differentiation of early melanomas from atypical nevi | Diagnóstico |
| A novel framework for supervised mobile assessment and risk triage of skin lesions | Diagnóstico |
| A Scenario-based Study of Doctors and Patients on Video Conferencing Appointments from Home | M. Sincrono |
| A system for the acquisition of reproducible digital skin lesions images | Acesso Pago |
| A two-stage approach for discriminating melanocytic skin lesions using standard cameras | Diagnóstico |
| Adaptable pattern recognition system for discriminating Melanocytic Nevi from Malignant Melanomas using plain photography images from different image databases | Diagnóstico |
| An image-based segmentation recommender using crowdsourcing and transfer learning for skin lesion extraction | Diagnóstico |
| An intelligent mobile based decision support system for retinal disease diagnosis | Diagnóstico |
| Application of Robust Zero-Watermarking Scheme Based on Federated Learning for Securing the Healthcare Data | Fora de Escopo |
| Artificial intelligence and machine learning algorithms for early detection of skin cancer in community and primary care settings: a systematic review | Diagnóstico |
| Artificial intelligence in dermatology for the clinician | Acesso Pago |
| Artificial Intelligence in Dermatology: A Primer | Diagnóstico |
| Artificial Intelligence in the detection of skin cancer | Diagnóstico |
| Assessing the International Transferability of a Machine Learning Model for Detecting Medication Error in the General Internal Medicine Clinic: Multicenter Preliminary Validation Study | Fora de Escopo |
| Assessment of the impact of teledermatology using discrete event simulation | Acesso Pago |
| Automatic detection of blue-white veil and related structures in dermoscopy images | Diagnóstico |
| Automatic segmentation of melanoma using superpixel region growing technique | Diagnóstico |
| Beyond JAAD July 2022 | Fora de Escopo |
| Blockchain technology in the healthcare industry: Trends and opportunities | Fora de Escopo |
| Cancer in sub-Saharan Africa: a Lancet Oncology Commission | Fora de Escopo |
| Characteristics of publicly available skin cancer image datasets: a systematic review | Fora de Escopo |
| Computer-aided classification of melanocytic lesions using dermoscopic images | Diagnóstico |
| Computer-aided melanoma diagnosis | Diagnóstico |
| Construction of an artificial intelligence system in dermatology: effectiveness and consideration of Chinese Skin Image Database (CSID) | Diagnóstico |
| COVID-19 and artificial intelligence: Experts and dermatologists perspective | Diagnóstico |
| Deep learning for dermatologists: Part I. Fundamental concepts | Diagnóstico |
| Deep learning for dermatologists: Part II. Current applications | Diagnóstico |
| Deep Learning in Dermatology: a systematic review of current approaches, outcomes and limitations | Diagnóstico |
| Dermatologic Follow-up and Assessment of Suspicious Lesions | Fora de Escopo |
| Dermoscopic assisted diagnosis in melanoma: Reviewing results, optimizing methodologies and quantifying empirical guidelines | Diagnóstico |
| Design and Implementation of a Calibrated Store and Forward Imaging System for Teledermatology | Fora de Escopo |
| Designing the Right Framework for Healthcare Decision Support | Fora de Escopo |
| Disease Classification based on Dermoscopic Skin Images Using Convolutional Neural Network in Teledermatology System | Diagnóstico |
| Does your dermatology classifier know what it doesn't know? Detecting the long-tail of unseen conditions | Diagnóstico |
| Dynamic knowledge validation and verification for CBR teledermatology system | Acesso Pago |
| Editorial: The Emerging Role of Artificial Intelligence in Dermatology | Diagnóstico |
| Evaluation of Artificial Intelligence-Assisted Diagnosis of Skin Neoplasms: A Single-Center, Parallelized, Unmasked, Randomized Controlled Trial | Diagnóstico |
| Evaluation of TELEDERM for dermatological services in rural and remote areas | Fora de Escopo |
| Evaluation of Telemedicine Systems: User Satisfaction in Developing Countries: The Case of Mali and Senegal | Fora de Escopo |
| Explainable artificial intelligence in skin cancer recognition: A systematic review | Diagnóstico |
| Fighting Melanoma with Smartphones: A Snapshot of Where We are a Decade after App Stores Opened Their Doors | Diagnóstico |
| Flexible macroblock ordering for context-aware ultrasound video transmission over mobile WMAX | Fora de Escopo |
| Fotografia digital en atención primaria | Otro idioma |
| Gastrointestinal cancer classification and prognostication from histology using deep learning: Systematic review | Fora de Escopo |
| Harvana: harvesting community tags to enrich collection metadata | Fora de Escopo |
| Hierarchy-aware contrastive learning with late fusion for skin lesion classification | Diagnóstico |
| HINT project: a BPM teleconsultation and telemonitoring platform | Fora de Escopo |
| Hippocr: Doctor-to-Doctor TeleDermatology consultation service towards future AI-based Diagnosis System in Japan | Diagnóstico |
| Human-Computer Collaborative Visual Design Creation Assisted by Artificial Intelligence | Fora de Escopo |
| Humans and Robots: A Mutually Inclusive Relationship in a Contagious World | Fora de Escopo |
| Image quality issues in teledermatology: A comparative analysis of artificial intelligence solutions | Diagnóstico |
| Image recognition system for diagnosis support of melanoma skin lesion | Diagnóstico |
| Improve Image-based Skin Cancer Diagnosis with Generative Self-Supervised Learning | Diagnóstico |
| Innovation in the pediatric electronic health record to realize a more effective platform | Fora de Escopo |
| Integrating Domain Knowledge into Deep Learning for Skin Lesion Risk Prioritization to Assist Teledermatology Referral | Diagnóstico |
| Integration of deep learning-based image analysis and genomic data in cancer pathology: A systematic review | Diagnóstico |
| Man against machine reloaded: performance of a market-approved convolutional neural network in classifying a broad spectrum of skin lesions in comparison with 96 dermatologists working under less artificial conditions | Diagnóstico |
| MED-NODE: A computer-assisted melanoma diagnosis system using non-dermoscopic images | Diagnóstico |
| Melanoma diagnosis and classification web center system: the non-invasive diagnosis support subsystem | Diagnóstico |
| Non-invasive optical methods for melanoma diagnosis | Diagnóstico |
| Open Set Deep Networks Based on Extreme Value Theory (EVT) for Open Set Recognition in Skin Disease Classification | Diagnóstico |
| Optimized Deep Learning Architectures and Techniques for Edge AI | Acesso Pago |
| Partnering with a senior living community to optimise teledermatology via full body skin screening during the COVID-19 pandemic: A pilot programme | M. Sincrono |
| Pigmented skin lesion computerized analysis via mobile devices | Diagnóstico |
| Reframing Telehealth: Regulation, Licensing, and Reimbursement in Connected Care | Fora de Escopo |
| Ridge and furrow pattern classification for acral lentiginous melanoma using dermoscopic images | Diagnóstico |
| Scars collaborative telediagnosis platform using adaptive image flow | Diagnóstico |
| Scientific papers: teledermatology: The patient's perspective | Fora de Escopo |
| Screening Feasibility and Comparison of Deep Artificial Neural Networks Algorithms for Classification of Skin Lesions | Diagnóstico |
| Sensors and healthcare 5.0: transformative shift in virtual care through emerging digital health technologies | Diagnóstico |
| Shading attenuation in human skin color images | Fora de Escopo |
| Simulation and Modeling Bandwidth Control in Wireless Healthcare Information Systems | Fora de Escopo |
| Skin cancer classification via convolutional neural networks: systematic review of studies involving human experts | Diagnóstico |
| Skin cancer detection by deep learning and sound analysis algorithms: A prospective clinical study of an elementary dermoscope | Diagnóstico |
| Skin Disease Analysis With Limited Data in Particular Rosacea: A Review and Recommended Framework | Diagnóstico |
| Skin lesions of face and scalp - Classification by a market-approved convolutional neural network in comparison with 64 dermatologists | Diagnóstico |
| Smart identification of psoriasis by images using convolutional neural networks: a case study in China | Diagnóstico |
| Software services for supporting remote crisis management | Fora de Escopo |
| Teleallergy: Where Have We Been and Where Are We Going? | Fora de Escopo |
| Teledermatology and its Current Perspective | Fora de Escopo |
| Telemedicine and e-Health in the Management of Psoriasis: Improving Patient Outcomes - A Narrative Review | Fora de Escopo |
| The mathematics of erythema: Development of machine learning models for artificial intelligence assisted measurement and severity scoring of radiation induced dermatitis | Diagnóstico |
| The Need for a National Strategy on Artificial Intelligence in Canadian Dermatology | Diagnóstico |
| The policy dimensions, regulatory landscape, and market characteristics of teledermatology in the United States | Acesso Pago |
| The role of technology in melanoma screening and diagnosis | Fora de Escopo |
| The use of noninvasive imaging techniques in the diagnosis of melanoma: a prospective diagnostic accuracy study | Diagnóstico |
| Towards development of IoT-ML driven healthcare systems: A survey | Fora de Escopo |
| User friendly decision support techniques in a case-based reasoning system | Fora de Escopo |
| User satisfaction with a smartphone-compatible, artificial intelligence-based cutaneous pigmented lesion evaluator | Diagnóstico |
| Using Artificial Intelligence as a Diagnostic Decision Support Tool in Skin Disease: Protocol for an Observational Prospective Cohort Study | Diagnóstico |
| Validation of a Skin-Lesion Image-Matching Algorithm Based on Computer Vision Technology | Diagnóstico |
| Virtual slide telepathology workstation-of-the-future: lessons learned from teleradiology | Fora de Escopo |
| What does it mean to provide decision support to a responsible and competent expert?: The case of diagnostic decision support systems | Fora de Escopo |

Fonte: Elaborado pelo autor (2023).

APÊNDICE B – CÓDIGOS DE INVALIDAÇÃO DO STT/SC

Quadro 2 – Códigos de Invalidação de exames.

| Nr. | Original Portuguese | English Translation |
|-----|--|--|
| 1 | Foto Panorâmica fora de foco ou ausente | Panoramic image out of focus or missing |
| 2 | Foto de dermatoscopia (contato) fora de foco ou ausente | Dermatoscopic (contact) image out of focus or missing |
| 3 | Foto dermatoscopia sem gel ou insuficiente. | Dermatoscopic image without or with not enough gel |
| 4 | Protocolo correto, porém, as fotos estão fora de foco, favor refazer o exame | Correct protocol, but images are out of focus. Please repeat examination |
| 5 | Lesões não identificadas | Lesions were not identified |
| 6 | Fotos trocadas | Exchanged images |
| 7 | Lesão não visualizada | Lesion not visible |
| 8 | Exame repetido | Repeated examination |
| 9 | Foto dos cotovelos e/ou joelhos ausente (psoríase) | Missing knees/elbows images (psoriasis) |
| 10 | Foto panorâmica de corpo inteiro (posterior) ausente | Panoramic whole body image (posterior) missing |
| 11 | Foto panorâmica de corpo inteiro (anterior) ausente | Panoramic whole body image (anterior) missing |
| 12 | Exame fora de protocolo | Examination out of protocol |
| 13 | Foto de aproximação (com régua) fora de foco ou ausente | Approximation image (with ruler) out of focus or missing |
| 14 | Falta foto de dermatoscopia (contato) | Dermatoscopic (contact) image missing |
| 15 | Foto panorâmica incompatível com a região solicitada | Panoramic image incompatible with requested region |
| 16 | Foto de dermatoscopia com luz desligada | Dermatoscopic image taken with light turned off |
| 17 | Tempo de doença não compatível com imagem enviada | Disease time incompatible with sent image |
| 18 | Fotos com a resolução abaixo da especificada - ajustar aparelho | Images with resolution below indicated, adjust equipment |
| 19 | Refazer o exame usando o protocolo (outras dermatoses) | Repeat examination using (other dermatoses) protocol |
| 20 | Incompatibilidade entre a descrição do paciente e as fotos | Incompatibility between patient description and images |
| 21 | Lesão encoberta total ou parcialmente | Lesion totally or partially covered |
| 22 | Dados do paciente incompatíveis | Incompatible patient data |

Fonte: Elaborado pelo Autor (2023)

APÊNDICE C – MATRIZ DO INTER-RATER AGREEMENT (IRA)

Tabela 8 – Matriz do Acordo entre Avaliadores

| Questão | r1 | r2 | r3 | r4 | r5 | r6 | r7 | r8 | r9 | r10 | r11 | A.I |
|---------|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|
| 1 | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes |
| 2 | no | no | no | no | no | no | no | no | no | no | no | no |
| 3 | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes |
| 4 | no | no | no | no | no | no | no | no | no | no | no | no |
| 5 | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes |
| 6 | no | no | no | no | no | no | no | no | no | no | no | no |
| 7 | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes |
| 8 | no | no | no | no | no | no | no | no | no | no | no | no |
| 9 | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes |
| 10 | no | no | no | no | no | no | no | no | no | no | no | no |
| 11 | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes |
| 12 | no | no | no | no | no | no | no | no | no | no | no | no |
| 13 | no | no | no | no | no | no | no | no | no | no | no | no |
| 14 | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes |
| 15 | yes | yes | no | yes | yes | yes | yes | yes | yes | yes | yes | yes |
| 16 | no | no | yes | no | no | no | no | no | no | no | no | no |
| 17 | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes |
| 18 | no | no | no | no | no | no | no | no | no | no | no | no |
| 19 | no | no | no | no | no | no | no | no | no | no | no | no |
| 20 | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes | yes |

Fonte: Elaborado pelo Autor (2023)

APÊNDICE D – EQUAÇÕES DAS MÉTRICAS DE AVALIAÇÃO

- **Intersection over Union (IoU):** Avaliação a sobreposição da região do objeto marcado no conjunto verdade com a região do objeto detectado na imagem conforme descrito na Equação (1).

$$IoU = \frac{GT \cap Prediction}{GT \cup Prediction} = \frac{I}{U} \quad (1)$$

- **Precision:** Indica com que frequência um determinado modelo está correto ao prever positivo, descrito pela Equação (2).

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

- **Recall:** É a proporção de todas as previsões rotuladas corretamente pelo nosso modelo para todos os rótulos no conjunto verdade, definido pela Equação (3).

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

- **F_1 Score:** É a média harmônica entre *precision* e *recall* de um modelo. É calculado conforme mostrado na Equação (4).

$$F_1 \text{ Score} = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

- **Average Precision (AP):** AP é uma métrica de valor único que representa a média de toda a precisão na curva *precision-recall*. AP é calculado de acordo com a Equação (5) onde o α assume um limiar de IoU. É utilizado um *loop* que passa por todos os pontos de precision-recall (pelo método de interpolação), para calcular a Área Sob a Curva (AUC) para cada classe. O mAP é o AP médio conforme descrito na Equação (6).

$$AP_\alpha = \sum_i^N (r_{i+1} - r_i) P_{interp}(r_{i+1}), \quad (5)$$

$$P_{interp}(r_{i+1}) = \max_{r:r' \geq r_{i+1}} P(r')$$

$$mAP_\alpha = \frac{1}{n} \sum_{i=1}^n AP_i \quad (6)$$

APÊNDICE E – MÉTRICAS COMPLEMENTARES FSCORE, PRECISION E RECALL POR CLASSE NO MÉTODO DE IMAGENS PANORÂMICAS

Tabela 9 – Fscore, Precision e Recall no conjunto padrão de panorâmicas por classe.

| Label | Fscore | Precision | Recall |
|--------------|---------------|------------------|---------------|
| pfrente | 68.14 | 64.41 | 72.33 |
| pcostas | 66.86 | 52.23 | 92.90 |
| wrong | 81.17 | 97.61 | 69.46 |

Fonte: Elaborado pelo autor (2023).

Tabela 10 – Fscore, Precision e Recall no conjunto rotacionado de panorâmicas por classe.

| Label | Fscore | Precision | Recall |
|--------------|---------------|------------------|---------------|
| pfrente | 76.88 | 66.01 | 92.04 |
| pcostas | 71.96 | 57.77 | 95.40 |
| wrong | 83.42 | 99.52 | 71.80 |

Fonte: Elaborado pelo autor (2023).