

**UNIVERSIDADE BRASIL
PÓS-GRADUAÇÃO EM ENGENHARIA BIOMÉDICA**

GUSTAVO CARLOS DA SILVA

**ALGORITMO PARA DETECÇÃO, CLASSIFICAÇÃO E
QUANTIFICAÇÃO DE RUGAS EM IMAGENS ÓPTICAS AMPLIADAS**

**ALGORITHM FOR DETECTION, CLASSIFICATION AND
QUANTIFICATION OF WRINKLES IN MAGNIFIED OPTICAL IMAGES**

São Paulo – SP
2023

GUSTAVO CARLOS DA SILVA

**ALGORITMO PARA DETECÇÃO, CLASSIFICAÇÃO E
QUANTIFICAÇÃO DE RUGAS EM IMAGENS ÓPTICAS AMPLIADAS**

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Engenharia Biomédica da Universidade Brasil, como parte dos requisitos necessários para obtenção do título de Doutor em Engenharia Biomédica.

Prof(a). Dr(a). Airton Abrahão Martin
Orientador(a)

São Paulo – SP
2023

FICHA CATALOGRÁFICA

Biblioteca da Universidade Brasil



TERMO DE APROVAÇÃO

GUSTAVO CARLOS DA SILVA

“ALGORITMO PARA DETECÇÃO, CLASSIFICAÇÃO E QUANTIFICAÇÃO DE RUGAS EM IMAGENS ÓPTICAS AMPLIADAS”

Tese aprovada como requisito parcial para obtenção do título de **Doutor no Programa de Pós-Graduação em Engenharia Biomédica** da Universidade Brasil, pela seguinte banca examinadora:

AIRTON ABRAHAO Assinado de forma digital
MARTIN:50813536 por AIRTON ABRAHAO
987 MARTIN:50813536987
Dados: 2023.06.30
17:16:13 -03'00'

Prof(a). Dr(a). Airton Abrahão Martin (presidente-orientador)

Prof(a). Dr(a). Priscila Pereira Fávero (UNIVERSIDADE BRASIL)

LAURITA DOS Assinado de forma digital
SANTOS:805873 por LAURITA DOS
48020 SANTOS:80587348020
Dados: 2023.06.30 19:45:35
-03'00'

Prof(a). Dr(a). Laurita dos Santos (UNIVERSIDADE BRASIL)



Prof(a). Dr(a). Lázaro Pinto Medeiros Neto (DERMOPROBES)

Prof(a). Dr(a). Alessandro Correa Mandes (TUPAN AIR)

São Paulo, 30 de junho de 2023.

Presidente da Banca Prof.(a) Dr.(a) Airton Abrahão Martin

Houve alteração do Título: sim () não (X):



Termo de Autorização

Para Publicação de Dissertações e Teses no Formato Eletrônico na Página WWW do Respeetivo Programa da Universidade Brasil e no Banco de Teses da CAPES

Na qualidade de titular(es) dos direitos de autor da publicação, e de acordo com a Portaria CAPES no. 13, de 15 de fevereiro de 2006, autorizo(amos) a Universidade Brasil a disponibilizar através do site <http://www.universidadebrasil.edu.br>, na página do respectivo Programa de Pós-Graduação *Stricto Sensu*, bem como no Banco de Dissertações e Teses da CAPES, através do site <http://bancodeteses.capes.gov.br>, a versão digital do texto integral da Dissertação/Tese abaixo citada, para fins de leitura, impressão e/ou *download*, a título de divulgação da produção científica brasileira.

A utilização do conteúdo deste texto, exclusivamente para fins acadêmicos e científicos, fica condicionada à citação da fonte.

Título do Trabalho: **“ALGORITMO PARA DETECÇÃO, CLASSIFICAÇÃO E QUANTIFICAÇÃO DE RUGAS EM IMAGENS ÓPTICAS AMPLIADAS”**.

Autor(es):

Discente: **Gustavo Carlos da Silva**

Documento assinado digitalmente

GUSTAVO CARLOS DA SILVA

Data: 07/12/2023 22:08:45-0300

Verifique em <https://validar.itl.gov.br>

Assinatura: _____

Orientador(a): **Prof.(a) Dr.(a) Airton Abrahão Martin**

Assinatura: _____

AIRTON ABRAHAO

Assinado de forma digital por

AIRTON ABRAHAO

MARTIN:50813536987

MARTIN:50813536987

Dados: 2023.06.30 14:49:35 -03'00'

Coorientador(a): **Prof.(a) Dr.(a)**

Assinatura: _____

Houve alteração do Título: sim () não (X):

Data: 30/06/2023

AGRADECIMENTOS

"Agradeço a Deus, pela força e guia que me concedeu durante todo este percurso. Em seguida, gostaria de agradecer a minha esposa Lília de Almeida e minha filha Lavínia Almeida por serem meu porto seguro e minha fonte de amor e motivação durante todo este percurso. Eu não teria conseguido chegar até aqui sem o seu constante apoio e compreensão.

Agradeço aos meus pais pelo dom da vida e por sempre me incentivarem no caminho dos estudos, e meus irmãos pelo companheirismo de sempre.

Agradeço ao meu orientador, professor e amigo, Dr. Airton Martin, por sua dedicação, paciência, e valiosos ensinamentos que compartilhou comigo. Este trabalho não teria sido possível sem a sua orientação e incentivo constante.

Agradeço ao Flávio Camargo, a Patrícia Moreira e a Rejane Werka por suas contribuições valiosas e por todas as conversas interessantes e produtivas que tivemos desde o início desse trabalho.

Agradeço ao Marcelo Golino e a Chemyunion por acreditarem que seria possível.

Agradeço a DermoPROBES e sua equipe por todo o apoio, em especial ao Miguel Brito pelas valiosas contribuições no desenvolvimento do software.

Gostaria de agradecer à Universidade Brasil e todo o corpo docente do programa de pós-graduação em Engenharia Biomédica por me proporcionar as condições ideais para a realização desta tese.

Agradeço a CAPES pelo financiamento dos meus estudos, sem o qual não seria possível a realização desse trabalho.

Por fim, agradeço a todos aqueles que, de alguma forma, contribuíram para a realização deste trabalho, seja com palavras de incentivo, ajuda financeira ou simplesmente ouvindo sobre o meu progresso. Obrigado a todos vocês."

EPÍGRAFE

“Observe a formiga, preguiçoso, reflita nos caminhos dela e seja sábio! Ela não tem nem chefe, nem supervisor, nem governante, e ainda assim armazena as suas provisões no verão e na época da colheita ajunta o seu alimento.”

Provérbios 6:6-8 (ARC)

RESUMO

A análise do relevo cutâneo é crucial no desenvolvimento de novos produtos para o cuidado da pele, bem como na avaliação de tratamentos dermatológicos. A análise pode ser realizada por métodos qualitativos ou quantitativos. No presente trabalho, propõe-se o desenvolvimento de um novo algoritmo para classificação, detecção e quantificação de rugas através do processamento de imagem de um dermatoscópio digital.

Foram realizados dois estudos clínicos, um com 90 participantes de pesquisa e outro com 33 participantes da pesquisa, nos quais foram coletadas imagens com o dermatoscópio e equipamento PRIMOS® para avaliação de rugas. No primeiro estudo foram coletadas imagens para a identificação de características dessa imagem, para posterior separação em grupos segundo os diferentes graus de rugas. No segundo estudo foram coletadas imagens em dois momentos distintos: Dia 0 (D0) e 45 dias (D45) após o uso de um produto dermocosmético.

Foi então realizada uma separação de grupos no conjunto de imagens coletadas no primeiro estudo, nos quais foi aplicado o treinamento de uma rede neural convolucional para a avaliação das imagens, a acurácia da rede neural foi de 78,5%.

Posteriormente, foi desenvolvido um novo algoritmo para detectar rugas nas imagens adquiridas no segundo estudo, através da aplicação de filtros e transformações de imagem que geram uma imagem segmentada destacando as rugas. A partir dos pixels pertencentes às rugas, é proposto um método de cálculo de rugosidade.

Verificou-se a correlação entre os valores obtidos pelo equipamento PRIMOS® e o sistema proposto. Não foi encontrada correlação para os dados obtidos em D0, porém, houve correlação no tempo D45 pelo coeficiente de similaridade de Spearman.

Ao comparar a rugosidade entre os tempos D0 e D45, o tratamento foi estatisticamente significativo tanto para o PRIMOS® quanto para os dados da metodologia proposta.

O algoritmo de detecção de rugas, além do cálculo da rugosidade, demonstrou sensibilidade comparável ao sistema PRIMOS® na avaliação da eficácia do tratamento dermocosmético, identificando diferenças entre tratamentos e a aplicação da rede neural convolucional demonstrou sensibilidade na classificação de rugas.

Considerando a simplicidade do design do dermatoscópio, em comparação com outros dispositivos consagrados como o PRIMOS®, o sistema proposto é promissor como alternativa para avaliações dermatológicas.

Palavras chave: Processamento de imagens, Rugas, Redes neurais

ABSTRACT

The analysis of skin relief is crucial in the development of new skin care products, as well as in the evaluation of dermatological treatments. The analysis can be performed by qualitative or quantitative methods. In the present work, it is proposed the development of a new algorithm for classification, detection, and quantification of wrinkles through the image processing from a digital dermatoscope.

Two clinical studies were carried out, one with 90 research participants and another with 33 research participants, in which images were collected with the dermatoscope and PRIMOS® equipment for the evaluation of wrinkles. In the first study, images were collected to identify characteristics of the images, for subsequent separation into groups according to the different degrees of wrinkles. In the second study, images were collected at two different times: Day 0 (D0) and after 45 days (D45) using a dermo cosmetic product.

A separation of groups was then performed on the set of images collected in the first study, in which the training of a convolutional neural network was applied to evaluate the images, the accuracy of the neural network was 78.5%.

Subsequently, a new algorithm was developed to detect wrinkles in the images acquired in the second study, through the application of filters and image transformations that generate a segmented image highlighting the wrinkles. From the pixels belonging to the wrinkles, a roughness calculation method is proposed.

The correlation between the values obtained by the PRIMOS® equipment and the proposed system was verified. No correlation was found for the data obtained at D0, however, there was a correlation at time D45 by Spearman's similarity coefficient.

When comparing the roughness between times D0 and D45, the treatment was statistically significant both for PRIMOS® and for the proposed methodology data.

The wrinkle detection algorithm, in addition to the roughness calculation, demonstrated sensitivity comparable to the PRIMOS® system in evaluating the efficacy of the dermo cosmetic treatment, identifying differences between treatments and the convolutional neural network was able to classify wrinkles.

Considering the simplicity of the dermoscope design, compared to other established devices such as the PRIMOS®, the proposed system is promising as an alternative for dermatological evaluations.

Keywords: Image processing, Wrinkles, Neural networks.

DIVULGAÇÃO E TRANSFERÊNCIA DE CONHECIMENTO

O trabalho aqui proposto, visa o desenvolvimento de algoritmos que habilitem um dispositivo dermatoscópio USB de baixo custo a fornecer informações relativas ao relevo cutâneo da pele de maneira comparável a dispositivos padrão-ouro.

O estudo foi realizado obtendo-se imagens de participantes de pesquisa utilizando-se o dispositivo dermatoscópio e o sistema PRIMOS®, após a coleta de dados, os algoritmos foram desenvolvidos de maneira tal que pudessem ser comparáveis com os parâmetros fornecidos pelo dispositivo padrão.

O resultado foi satisfatório, uma vez que os resultados apresentados pelo dispositivo de baixo custo apresentou um resultado com nível de sensibilidade próximo ao padrão.

LISTA DE FIGURAS

Figura 1 – Escala de Fitzpatrick.....	20
Figura 2 – Escala de Glogau	21
Figura 3 -Exemplo de segmentação	26
Figura 4 - Representação de um neurônio	30
Figura 5 - Representação de uma rede neural com três camadas	31
Figura 6 - Representação de uma CNN para classificação de imagem	33
Figura 7 – Esquema representando as partes que compõe o dermatoscópio USB .	37
Figura 8 – Dispositivo dermatoscópio USB.....	37
Figura 9 – Sistema PRIMOS®.....	38
Figura 10 – Imagem obtida pelo sistema PRIMOS® aberto no software de análise	39
Figura 11 – Região periorbital analisada	39
Figura 12 – Imagem obtida pelo dispositivo dermatoscópio:	42
Figura 13 – Imagem original (A) e imagem com a aplicação do mapa de cores (B).	43
Figura 14 – Imagens processadas com operações lógicas AND (A), NOT (B), OR (C) e XOR (D).....	44
Figura 15 – Dendrograma analisando resultados obtidos pelo sistema PRIMOS®..	45
Figura 16 – Resultados do kNN.....	45
Figura 17 – Boxplots representando a distribuição de valores de Ra nos quatro grupos definidos	46
Figura 18 – Histograma representando a distribuição de valores de Ra nos quatro grupos definidos	46
Figura 19 – Descrição do modelo proposto	49
Figura 20 – Visualização 3D das camadas da rede.....	50
Figura 21 – Exemplos de imagens em cada grupo de treinamento da CNN	51
Figura 22 – Distribuição dos valores relativos ao cálculo de momento da imagem..	52
Figura 23 – Distribuição dos valores relativos à média do histograma das imagens	52
Figura 24 – Distribuição dos valores relativos ao cálculo da textura de cada imagem	53
Figura 25 – Primeira etapa da abordagem proposta, classificação via rede neural..	54
Figura 26 – Etapa de quantificação da textura	54
Figura 27 – Algoritmo de segmentação de áreas de rugas	56

Figura 28 – Resultados da etapa de segmentação	57
Figura 29 – Imagem segmentada sobreposta a imagem original	57
Figura 30 – Exemplo de análise, região periorbital (A), imagem PRIMOS® (B), imagem dermatoscópio (C) e resultado da segmentação (D)	60
Figura 31 – Exemplos de imagens processadas	60
Figura 32 – Resultados Ra obtidos pelo sistema PRIMOS®	62
Figura 33 – Resultados Ra obtidos pelo sistema proposto	62
Figura 34 – Resultados Rq obtidos pelo sistema proposto	63

LISTA DE TABELAS

Tabela 1 – Parâmetros fornecidos pelo sistema PRIMOS®.....	23
Tabela 2 – Parâmetros fornecidos pelo sistema PRIMOS®.....	53
Tabela 3 – Testes de normalidade para cada um dos parâmetros mensurados.....	61

SUMÁRIO

1 INTRODUÇÃO	15
2 OBJETIVOS	16
2.1 Objetivos Específicos	16
3 REVISÃO DA LITERATURA	17
3.1 Avaliação da pele humana	17
3.2 Rugas	20
3.3 Processamento de imagens aplicados a pele	23
3.4 Técnicas de segmentação de imagens	26
3.5 Valores quantitativos a partir de imagens digitais	27
3.6. Algoritmos de classificação	28
3.7. Redes neurais convolucionais	29
4 METODOLOGIA	35
4.1 Tipo de Estudo	35
4.2 Aspectos éticos e legais	35
4.3 Local da Pesquisa	35
4.4 Seleção de Voluntários da Pesquisa	35
4.5 Instrumentos utilizados	36
4.5.1 Câmera de alta resolução	36
4.5.2 Dispositivo Dermatoscópio USB	36
4.5.3 Sistema PRIMOS®.....	38
4.6 Coleta de dados	39
4.6.1 Fase 1	40
4.6.2 Fase 2.....	40
4.7 Processamento de imagens	40
4.7.1 Imagens de treino CNN	40
4.7.2 Imagens para extração de características	41
4.8 Análise estatística	41

5 RESULTADOS.....	42
5.1 Classificação de Rugas	42
5.1.1 Pré-processamento de imagens	42
5.1.1 Separação de grupos para treinamento da CNN.....	44
5.1.2 Arquitetura da CNN	47
5.1.3 Treinamento da CNN	50
5.1.4 Avaliação da CNN	51
5.1.5 Análises complementares	51
5.2 Análise quantitativa de rugas.....	55
5.2.1 Segmentação da imagem	55
5.2.2 Análise de Rugosidade	58
5.2.3 Área de Rugas.....	59
5.2.4 Valores obtidos.....	59
5.2.5 Comparação com PRIMOS®.....	61
6 DISCUSSÃO.....	64
7 CONCLUSÃO	65
REFERÊNCIAS.....	66
APÊNDICE A – Parecer CEP – Fase 1.....	72
APÊNDICE B – Parecer CEP – Fase 2.....	75

1 INTRODUÇÃO

O envelhecimento da pele é um processo natural que afeta a aparência e a saúde da pele. Uma das principais características desse envelhecimento é a aparência de rugas. A detecção precisa e a quantificação dessas rugas é importante não apenas para fins estéticos, mas também para monitorar a saúde da pele e avaliar o efeito de tratamentos antienvelhecimento. Diante disso, o desenvolvimento de um algoritmo de detecção de rugas se torna fundamental para oferecer uma solução eficaz e precisa para esse problema.

O uso de tecnologia de computação e aprendizado de máquina pode fornecer uma avaliação objetiva e padronizada da presença de rugas, além de ser uma ferramenta útil para acompanhar a evolução dessas marcas ao longo do tempo. A criação desse algoritmo é importante para melhorar a avaliação da saúde da pele, ajudar na escolha de tratamentos eficazes e fornecer uma ferramenta valiosa para a indústria de cuidados com a pele.

Além disso, o mercado de dermatologia está em constante crescimento e procura por soluções inovadoras e eficazes para o envelhecimento da pele. De acordo com uma pesquisa recente, o mercado global de cuidados com a pele deve ultrapassar US\$ 180 bilhões até 2027 (Grand View Research, 2020). Isso indica uma grande demanda por produtos e tratamentos antienvelhecimento, incluindo soluções de detecção de rugas.

Atualmente estão disponíveis no mercado, diferentes tipos de equipamentos com a finalidade de realizar análises quantitativas relacionadas a rugas, porém encontram-se dois fatores impeditivos para a popularização dessa tecnologia, a primeira é que os dispositivos com validação científica possuem alto custo, sendo encontrados apenas em grandes clínicas, institutos de pesquisa e em universidades, o segundo é que os dispositivos de baixo custo não demonstram confiabilidade nas informações que fornecem.

O desenvolvimento de um algoritmo de detecção de rugas também pode ter um impacto positivo no setor médico, ajudando dermatologistas e profissionais de saúde a avaliar de forma mais precisa a condição da pele de seus pacientes. A tecnologia pode ser ainda utilizada em consultórios dermatológicos e clínicas de beleza para fornecer aos pacientes uma avaliação objetiva e quantificável da aparência das rugas. Em conclusão, o desenvolvimento de um algoritmo de detecção de rugas pode ter um impacto significativo no mercado de cuidados com a pele, ajudando a melhorar a avaliação da saúde da pele, a seleção de tratamentos eficazes e a oferecer soluções inovadoras para o envelhecimento da pele.

2 OBJETIVOS

Desenvolvimento de um algoritmo para detecção e quantificação de rugas

2.1 Objetivos Específicos

- Obter um valor quantitativo que represente níveis de rugas em comparação com o dispositivo padrão-ouro
- Realizar uma classificação de imagens que represente os diferentes níveis de rugas

3 REVISÃO DA LITERATURA

3.1 Avaliação da pele humana

O estudo da pele, também conhecido como dermatologia, tem uma longa história que remonta à antiguidade. No entanto, a dermatologia moderna começou a se desenvolver no século XIX, com o surgimento da microscopia e da química, que permitiram aos cientistas e médicos estudar a pele em níveis cada vez mais detalhados. A dermatologia tem vindo a evoluir ao longo dos anos, com o desenvolvimento de novos tratamentos e tecnologias para a avaliação e tratamentos da pele.

A avaliação da pele humana é uma área importante da dermatologia, pois permite identificar problemas de pele e escolher o melhor tratamento para cada caso. Existem diversas técnicas utilizadas para avaliar a pele, que incluem análise clínica, avaliação instrumental e avaliação subjetiva (LIM et al., 2006).

A análise clínica da pele é uma técnica utilizada para avaliar a saúde e a aparência da pele. Ela envolve uma avaliação visual e tátil da pele, incluindo a sua cor, textura, hidratação, elasticidade e outros aspectos. Tal análise é realizada por profissionais da saúde, como dermatologistas, médicos estéticos ou enfermeiros dermatologistas, e pode ser feita para ajudar a diagnosticar condições de pele, avaliar o efeito de tratamentos anteriores e planejar o tratamento futuro (SATTLEER et al., 2008). É uma técnica importante, pois a pele é o maior órgão do corpo e pode ser afetada por uma ampla variedade de fatores, incluindo a idade, a exposição solar, a genética e doenças. Além disso, a pele pode ser um indicador importante da saúde geral, pois muitas condições de pele estão relacionadas a problemas de saúde subjacentes. É importante lembrar que a eficácia da análise clínica da pele depende do profissional da saúde que a realiza e da qualidade dos instrumentos utilizados.

As avaliações instrumentais da pele são técnicas que utilizam dispositivos eletrônicos para medir as características da pele de forma objetiva. Estas avaliações são complementares à análise clínica da pele e podem fornecer informações adicionais sobre a hidratação, a espessura, a elasticidade, a cor e outras características da pele. Além disso, as avaliações instrumentais da pele podem ser repetidas ao longo do tempo para acompanhar a evolução das características da pele e avaliar o efeito de tratamentos. Os instrumentos padrão-ouro para avaliar as características da pele incluem:

- Hidratação da pele: o corneômetro é o instrumento para avaliar a hidratação da pele. Este dispositivo mede a resistência elétrica da pele, que é inversamente proporcional à sua hidratação (DRAELOS et al., 2002).
- Elasticidade da pele: o cutômetro é utilizado na avaliação da elasticidade da pele. Este dispositivo mede a capacidade da pele de se esticar e retornar à sua forma original após a aplicação de uma pressão suave (KALKA-MOLL et al., 2002).
- Cor da pele: o colorímetro é o instrumento para avaliar a cor da pele. Este dispositivo mede a reflectância da luz da pele em diferentes comprimentos de onda, fornecendo informações sobre a cor da pele e a presença de manchas (DRAELOS et al., 2007).
- Textura da pele: o profilômetro é o instrumento padrão para avaliar a textura da pele. Este dispositivo mede as elevações e recessos da superfície da pele, fornecendo informações sobre sua textura (KOK et al., 2017).

Estes são apenas alguns exemplos dos muitos instrumentos disponíveis para avaliar as características da pele. É importante lembrar que cada dispositivo tem suas próprias limitações e que a combinação de avaliações clínicas e instrumentais pode fornecer uma visão mais completa da saúde e aparência da pele.

Por fim, a avaliação subjetiva é baseada nas percepções e julgamentos do indivíduo sobre a aparência e saúde da sua pele. Por exemplo, a autoavaliação da pele pode ser realizada por meio de questionários ou escalas de avaliação subjetiva da pele. As avaliações subjetivas da pele são baseadas nas percepções e julgamentos do indivíduo sobre as características de sua pele, como hidratação, elasticidade, cor, textura, entre outras (MELO & MAIA CAMPOS, 2018). Essas avaliações são realizadas sem o uso de instrumentos e geralmente incluem questionários ou escalas de autoavaliação. Algumas das características da pele que podem ser avaliadas de forma subjetiva incluem:

- Hidratação da pele: o indivíduo é solicitado a avaliar o grau de hidratação da pele em uma escala, como "muito seca", "moderadamente seca" ou "hidratada".
- Elasticidade da pele: o indivíduo é solicitado a avaliar a flexibilidade e elasticidade da pele, como "alta elasticidade" ou "baixa elasticidade".
- Cor da pele: o indivíduo é solicitado a avaliar a uniformidade e a tonalidade da cor da pele, como "uniforme" ou "irregular".

- Textura da pele: o indivíduo é solicitado a avaliar a aparência da textura da pele, como "lisa" ou "rugosa".

Essas avaliações subjetivas são úteis para fornecer uma visão geral da percepção do indivíduo sobre as características de sua pele, mas têm algumas limitações. Por exemplo, a percepção pode ser influenciada por fatores subjetivos, como expectativas e percepções pessoais. Além disso, a falta de objetividade e a dependência de fatores subjetivos podem levar a avaliações inconsistentes ou imprecisas.





Em resumo, as avaliações subjetivas da pele são uma parte importante da avaliação da pele, pois fornecem uma visão geral da percepção do indivíduo sobre sua pele, mas devem ser complementadas por avaliações objetivas para obter uma avaliação completa e precisa.

As escalas de classificação da pele são uma ferramenta importante para avaliar de forma objetiva e padronizada as características da pele, mas devem ser utilizadas com cuidado e em combinação com outras formas de avaliação da pele.

A Escala de Fitzpatrick é uma escala de classificação da cor da pele amplamente utilizada em dermatologia e em outras áreas da medicina (FITZPATRICK et al., 1975). Ela foi desenvolvida por Thomas B. Fitzpatrick, no início da década de 1970 e é baseada na observação da resposta da pele ao sol. A Escala de Fitzpatrick é composta por seis tipos de cor de pele, que vão desde o tipo 1 (muito claro, com tendência a queimar facilmente) até o tipo VI (escuro, com tendência a se bronzear), conforme verificado na Figura 1. A escala é utilizada para prever a reação da pele ao sol, incluindo a propensão a desenvolver queimaduras solares e manchas, bem como a propensão a desenvolver câncer de pele. Essa escala é amplamente utilizada como referência para determinar a quantidade de proteção solar necessária para cada tipo de cor de pele, bem como para avaliar a eficácia de produtos para cuidados com a pele. Além disso, é amplamente aceita como uma forma padronizada de classificar a cor da pele em estudos clínicos e pesquisas, sendo uma ferramenta útil para avaliar a cor da pele de forma objetiva e padronizada. No entanto, é importante lembrar que a cor da pele pode ser influenciada por fatores além da genética, como exposição ao sol, uso de medicamentos e idade, e que a escala pode não ser adequada para avaliar todas as características da pele.

Figura 1 – Escala de Fitzpatrick



					
Tipo I	Tipo II	Tipo III	Tipo IV	Tipo V	Tipo VI
Pele muito branca, cabelos ruivos	Pele branca, cabelos claros	Pele clara, cabelos variáveis	Pele moderadamente pigmentada	Pele em tom marrom claro	Pele marrom escuro
Queima facilmente, nunca bronzeia	Queima facilmente, bronzeia muito pouco	Queima um pouco e bronzeia gradualmente	Raramente queima e bronzeia com facilidade	Não queima e bronzeia	Bronzeia facilmente

Fonte: Adaptado de Medspa (2023)

3.2 Rugas

As rugas são linhas ou marcas que aparecem na pele como resultado do envelhecimento, exposição ao sol e outros fatores, como fumo, dieta e estresse. Elas podem afetar diferentes áreas do rosto, como testa, olhos, boca e pescoço, elas são causadas pela perda de elasticidade e colágeno na pele, que é uma proteína importante para a firmeza e sustentação da pele. A exposição ao sol também pode danificar a pele, acelerando o processo de envelhecimento e a formação de rugas. Existem diversas formas de tratar as rugas, incluindo cremes antienvhecimento, terapias com luz e laser, preenchimentos dérmicos e procedimentos cirúrgicos, como a cirurgia plástica facial. No entanto, é importante lembrar que o melhor tratamento para as rugas depende da sua causa e da severidade dos sinais de envelhecimento. Além disso, há medidas que podem ser tomadas para prevenir ou minimizar a formação de rugas, como evitar exposição excessiva ao sol, fazer uma dieta saudável e equilibrada, evitar fumar e usar cremes hidratantes e protetores solares (VARANI et al., 2006). Em resumo, as rugas são uma parte natural do envelhecimento da pele, mas existem maneiras de tratá-las e preveni-las.

Para avaliar as rugas, é comum utilizar escalas de medida subjetivas e objetivas. As escalas subjetivas, envolvem a avaliação da aparência das rugas por um especialista ou

por uma pessoa treinada. As escalas objetivas, utilizam medidas quantitativas, como espessura e comprimento da ruga, para a avaliação. A Escala de Glogau é uma escala subjetiva utilizada para avaliar o grau de flacidez e rugas da pele (GLOGAU et al., 1997). A escala foi desenvolvida por Richard Glogau, e é composta por quatro categorias, que vão desde pele "jovem e firme" a pele "idosa e flácida", sendo os tipos I, II, III, e IV, sendo a classificação realizada com base na avaliação subjetiva do médico ou de outro especialista, a Figura 2 demonstra cada um dos tipos. A Escala de Glogau é amplamente utilizada na dermatologia e na indústria cosmética para avaliar o efeito de diferentes tratamentos na pele, como cremes antienvelhecimento, preenchimentos dérmicos e procedimentos cirúrgicos. A escala é considerada uma ferramenta útil para avaliar a aparência da pele, mas é importante destacar que a classificação subjetiva pode não ser tão precisa quanto as avaliações objetivas, como imagens de luz polarizada e medidas da profundidade da ruga.

Figura 2 – Escala de Glogau

Tipo 1	Tipo 2	Tipo 3	Tipo 4
(a) 	(b) 	(c) 	(d) 
<ul style="list-style-type: none"> • Ausência de rugas • 20-30 anos • Poucas alterações pigmentares • Ausência de lesões queratósicas 	<ul style="list-style-type: none"> • Rugas dinâmicas • 30-40 anos • Lentigos senis iniciais • Queratoses palpáveis (não-visíveis) 	<ul style="list-style-type: none"> • Rugas estáticas • Acima de 50 anos • Melanoses e telangiectasias • Queratoses visíveis 	<ul style="list-style-type: none"> • Somente rugas • Acima dos 60 anos • Coloração amarelo-acinzentada • Pode ter lesões malignas • Pele actínica

Fonte: Callaghan (2008)

Além disso, existem análises instrumentais para avaliar as rugas, como imagens de luz polarizada, fotografias de pele, análise de imagem computadorizada e medidas de profundidade da ruga com tecnologias como o profilômetro. Esses instrumentos objetivos

permitem a avaliação precisa das rugas e a comparação dos resultados entre diferentes indivíduos ou entre diferentes momentos.

As técnicas de análise de imagens para a extração de características têm obtido grande avanço nos estudos relacionados a pele, um dos sistemas mais utilizados e considerado o padrão-ouro para avaliação de rugas é o PRIMOS® (Canfield, Inc) que foi desenvolvido com o foco em fornecer valores quantitativos para o estudo e entendimento da pele humana, seu funcionamento baseia-se na utilização da técnica de incidência de luz na superfície da pele em diferentes ângulos através de microespelhos (JASPERS et al, 1999), essa técnica é conhecida como projeção de Fringe, que evidencia as questões do relevo a ser analisado, o nome PRIMOS® é uma abreviação para seu princípio de funcionamento **Phaseshift Rapid In vivo Measurement Of the Skin**, que consiste basicamente na projeção de faixas de luz paralelas com diferenças de mínimas de angulação, tudo isso sendo realizado pela utilização de microespelhos conforme descrito por Jaspers. O equipamento PRIMOS® é capaz de fornecer alguns parâmetros conforme Tabela 1, inclusive com parâmetros de rugosidade (Ra, Rz e Ry), sendo o mais utilizado para a determinação de rugas o parâmetro Ra que pode ser calculado considerando-se toda a área da medida ou através da demarcação de linhas em pontos de interesse no software de processamento disponibilizado em conjunto com o sistema. Outros dispositivos que podem ser citados para a análise do relevo cutâneo são o VisioScan VC98 (Kourage Kasaka), que é um vídeo dermatoscópio que possui uma câmera de alta resolução e fontes de luz LED e UV, para estudar principalmente questões sobre hidratação da superfície da pele, já o sistema VISIA® (Canfield, Inc) realiza a análise da pele através da utilização de imagens multiespectrais, e apresenta resultados detalhadas de diferentes características da pele.

Em suma, existem diferentes tipos de rugas, e a avaliação das rugas pode ser realizada por meio de escalas de medida subjetivas e objetivas, bem como por meio de instrumentos instrumentais. As escalas objetivas permitem a avaliação precisa das rugas e a comparação dos resultados entre diferentes indivíduos ou entre diferentes momentos.

Tabela 1 – Parâmetros fornecidos pelo sistema PRIMOS®

Parâmetro	Unidade
Contagem de rugas	nd*
Profundidade média de rugas	μm
Ruga mais profunda	μm
Área total de rugas	mm^2
Volume total de rugas	mm^2
Fator de fator de formas de rugas	nd*
Tamanho total de rugas	mm
Ra	μm
Ry	μm
Rz	μm

*nd = não dimensional

Fonte: Autoria própria.

3.3 Processamento de imagens aplicados a pele

As análises de imagem da pele são técnicas que utilizam dispositivos especializados, como câmeras, lasers ou sistemas de imagem, para produzir imagens detalhadas da pele. Estas imagens são então analisadas por software especializado para produzir medições objetivas da pele, como a profundidade das rugas, a espessura da camada córnea, a distribuição de melanina e o tamanho dos poros.

Existem vários tipos diferentes de análises de imagem da pele, incluindo imagem por tomografia de reflectância confocal (CRT), análise de imagem do microrelevo (MRA) e análise de imagem da textura da pele (STA). Cada técnica utiliza uma combinação de luz e câmeras para produzir imagens da pele, e cada técnica produz informações diferentes sobre a estrutura e a função da pele.

As análises de imagem da pele são amplamente utilizadas na dermatologia, cosmética e em pesquisas clínicas para avaliar a eficácia de tratamentos para a pele, incluindo cremes, procedimentos de rejuvenescimento e tratamentos para rugas. As medições objetivas produzidas por estas técnicas de imagem podem ser comparadas ao longo do tempo para avaliar a evolução da pele e a eficácia dos tratamentos. A avaliação

de rugas por imagens é uma técnica que tem sido utilizada com frequência para medir a profundidade e a quantidade de rugas na pele. Conforme mencionado anteriormente, o equipamento padrão para a medição de parâmetros referentes a rugas é o PRIMOS®, alguns estudos clínicos podem ser verificados na comparação com resultados obtidos pelo PRIMOS®, inclusive outros equipamentos que utilizam diferentes abordagens.

Um exemplo é o sistema Visioscan VC98 (Courage & Kasaka, Inc), que é um vídeo dermatoscópi que possui uma câmera de alta resolução com iluminação de luz UVA, as imagens otidas por esse dispositivo passam por uma etapa de processamento desenvolvida por Tronier conhecida como SELS(Surface Evaluation of the Lining Skin) (TRONIER et al., 1999). Diversos microscópios digitais estão disponíveis com a finalidade de serem dermatoscópio de baixo custo, que possuem a capacidade de capturar imagens de alta resolução com nível de aumento que chega a 100 vezes, porém os softwares disponíveis com esses dispositivos não apresentam confiança e evidência científica nos valores quantitativos que fornecem.

Suprijanto et al (2011) propôs um método de avaliação da rugosidade da pele a partir de imagens de um dermatoscópio digital através da utilização de filtros da transformada de Fourier. A análise de imagens de câmeras digitais também é utilizada na verificação da qualidade do relevo da pele, através de técnicas de processamento de imagens, diversos artigos demonstram métodos para a detecção de rugas e contagem, além da determinação da idade dos indivíduos através dos tipos de rugas presentes. A área de visão computacional compreende a aplicação de técnicas matemáticas ao processamento de imagens, de maneira tal que seja possível a obtenção de características específicas de acordo com o interesse da aplicação, em análises relacionadas a pele, diversos autores têm proposto algoritmos que evidenciem características da pele, principalmente rugas.

Yap et al (2021) demonstram um resumo dos principais algoritmos de detecção e reconstrução de rugas na pele da face, dentre os quais pode-se destacar o método Cula onde foi definido o Wrinkle Index (WI), como o produto da profundidade e largura da ruga, sendo a largura definida pela derivada de primeira ordem e a profundidade como sendo a resposta do filtro Gabor, além dos métodos que se utilizam da matriz hessiana na determinação de rugas, o Hybrid Hessian Filter e o Hessian Line Tracking que são as técnicas mais recentes. A EN ISO 4287 define padrões para cálculo de rugosidade de

superfícies mecânicas como por exemplo a média aritmética da Rugosidade (R_a), raiz quadrada da rugosidade média (R_q) e rugosidade máxima (R_{max}), sendo que o principal parâmetro para cálculo dessas grandezas é a medida de profundidade da superfície em análise, um dos principais parâmetros mais utilizados na análise de pele pelo PRIMOS® é o R_a .

Askaruly et al (2018) propôs o desenvolvimento de um dispositivo que faz a utilização de tomografia de coerência óptica e a verificação da correlação dos resultados obtidos em comparação aos dados obtidos utilizando o sistema PRIMOS®.

A técnica de avaliação de rugas por imagens tem sido amplamente estudada e validada por diversos artigos científicos. Um exemplo é o estudo "Comparison of Validated Assessment Scales and 3D digital fringe projection method to assess lifetime development of wrinkles in men" (LUEBBERDING et al 2014), neste estudo, os autores avaliaram a precisão e a validade do sistema PRIMOS® na avaliação da severidade das rugas na pele em relação a idade. Outro exemplo é o estudo "Efficacy of anti-wrinkle products in skin surface appearance: a comparative study using non-invasive methods", publicado na revista Skin Research and Technology em 2010 (FERREIRA et al., 2010). Neste estudo, os autores avaliaram o uso do sistema Visioscan VC98 para a avaliação da quantidade e da profundidade de rugas na pele.

Esses estudos e outros similares apontam para a validade e precisão da avaliação de rugas por imagens como uma técnica útil e confiável para a avaliação objetiva das rugas na pele. Existem várias técnicas computacionais que são aplicadas em processamentos de imagens para avaliar rugas, incluindo:

- **Análise de Textura:** As técnicas de análise de textura são usadas para medir a homogeneidade da superfície da pele e, portanto, a presença de rugas.
- **Segmentação de Imagem:** A segmentação de imagem é a técnica que divide a imagem em diferentes regiões para facilitar a análise e a medição. É frequentemente usada para destacar as rugas e outros sinais de envelhecimento da pele.
- **Reconhecimento de Padrões:** O reconhecimento de padrões é uma técnica computacional que permite identificar e classificar padrões em uma imagem, incluindo rugas.

- **Análise de Morfologia Matemática:** A análise de morfologia matemática é uma técnica que usa conceitos matemáticos para medir características estruturais da pele, incluindo rugas.


3.4 Técnicas de segmentação de imagens

A segmentação de imagem é um processo importante em processamento de imagem e visão computacional. O objetivo é dividir uma imagem em diferentes regiões ou objetos distintos, com base em determinadas características, tais como cor, intensidade, textura e forma. A segmentação é fundamental para a realização de várias tarefas em computação gráfica, como remoção de ruído, melhoria de imagem, detecção de objetos, rastreamento, entre outras (SAHA et al., 2010). Além disso, é uma etapa crítica em muitos sistemas de visão artificial e reconhecimento de imagem.

Existem vários métodos de segmentação de imagens, tais como segmentação baseada em limiar, segmentação baseada em regiões, segmentação baseada em modelos, entre outros. A escolha do método a ser utilizado depende do tipo de imagem e das características que se deseja destacar. A segmentação é uma etapa importante em vários processos de análise de imagem, incluindo a análise de pele, uma vez que permite a extração de informações precisas e relevantes a partir da imagem original.

Na avaliação da pele, a segmentação de imagens se mostra uma ferramenta crucial na identificação de regiões de interesse para cada característica que se deseja investigar, classificar ou quantificar, uma ilustração sobre segmentação em uma imagem pode ser verificada na Figura 3, em que é possível identificar os pixels da imagem correspondentes ao avião.

Figura 3 -Exemplo de segmentação



Fonte: Venkatesan (2018)

3.5 Valores quantitativos a partir de imagens digitais

As imagens digitais são representadas como uma matriz de pixels, onde cada pixel representa uma cor específica. Cada pixel é codificado como uma combinação de valores de cor, como os padrões RGB (vermelho, verde e azul) ou HSL (matiz, saturação e luminosidade). A resolução da imagem é definida pelo número de pixels na imagem. Quanto maior o número de pixels, mais detalhada é a imagem (BAZZI et al., 2011).

Além da representação de cor, outras informações como intensidade de luz e textura podem ser extraídas de uma imagem digital. Estas informações são importantes para aplicações de processamento de imagem, como a análise de rugas. As informações são representadas como matrizes numéricas, estas matrizes podem ser manipuladas para extrair informações adicionais, como a identificação de contornos e formas, ou para aplicação de filtros para melhorar a qualidade da imagem.

Existem vários formatos de imagem utilizados na representação de imagens no computador, incluindo JPEG, PNG, BMP, TIFF e GIF. Cada formato tem suas próprias vantagens e desvantagens, como tamanho do arquivo, qualidade da imagem e suporte a transparência.

Os valores quantitativos que podem ser obtidos a partir de uma imagem digital incluem medidas de área, comprimento, largura, perímetro, diâmetro, entre outros. Além disso, também é possível obter informações sobre a intensidade de cor e brilho de pixels individuais ou de regiões específicas da imagem. É possível também obter medidas de distância, ângulo, posição e orientação. Estes valores quantitativos são úteis em várias aplicações, incluindo análise de imagens médicas, processamento de imagens de satélite ou recuperação de informações. Alguns destes valores quantitativos podem ser utilizados como entrada para outros processos, tais como classificação, detecção de bordas e análise de textura.

A análise de rugosidade em imagens se mostra como um importante parâmetro que possui uma relação direta com a quantidade e profundidade de rugas, quanto mais rugas ou mais profundas elas forem, uma análise de rugosidade apresentará valores altos, ao passo que a ausência de rugas demonstra valores de rugosidade baixos.

3.6. Algoritmos de classificação

Os algoritmos de classificação são técnicas computacionais que permitem categorizar dados em diferentes classes ou grupos. Eles são amplamente utilizados em muitas aplicações, como a detecção de fraudes, a classificação de sentimentos em comentários de mídia social, a análise de sentimentos em análise de dados de mercado, a análise de imagens médicas, dentre as mais variadas aplicações.

A classificação de imagens é uma tarefa importante em diversas áreas, como visão computacional, inteligência artificial e análise de imagens médicas. A classificação é o processo de atribuir uma categoria ou classe a uma imagem, baseada em suas características e informações.

Existem vários tipos de algoritmos de classificação, como por exemplo, árvores de decisão, k-Nearest Neighbor (k-NN), Support Vector Machines (SVM). Cada algoritmo é projetado para atender a requisitos específicos e é escolhido de acordo com a natureza dos dados de entrada e a precisão desejada na classificação (HASTIE et al., 2009). Dentre os algoritmos, lista-se a seguir alguns que podem ser aplicados a imagens:

- Algoritmos baseados em Regressão Logística: Este algoritmo é amplamente utilizado para classificação binária, ou seja, quando há apenas duas possíveis categorias. A Regressão Logística é baseada em equações matemáticas que permitem modelar a relação entre as características da imagem e a categoria a ser atribuída.
- Algoritmos baseados em Árvores de Decisão: Este algoritmo constrói uma árvore de decisão com base nas características da imagem e na categoria correspondente. A árvore de decisão permite fazer previsões sobre a categoria de uma nova imagem, seguindo uma sequência de decisões lógicas baseadas nas características.
- Algoritmos baseados em Redes Neurais: As Redes Neurais são modelos computacionais inspirados no funcionamento do cérebro humano. Elas são amplamente utilizadas para classificação de imagens, pois podem modelar relações complexas entre as características da imagem e a categoria correspondente.
- Algoritmos baseados em SVM (Support Vector Machines): Este algoritmo é utilizado para classificação binária e multi-categórica. O SVM é baseado em técnicas matemáticas que permitem encontrar a fronteira de separação ótima entre as categorias, com base nas características da imagem.

Cada algoritmo de classificação possui suas próprias vantagens e desvantagens, e a escolha do melhor algoritmo depende das características da imagem e do problema de classificação específico. Além disso, é importante levar em consideração a eficiência computacional, a facilidade de interpretação dos resultados e a capacidade de generalização para novas imagens. A escolha do algoritmo de classificação apropriado é crucial para o sucesso da classificação. Além disso, é importante realizar uma validação rigorosa dos resultados obtidos para garantir a precisão da classificação (DOMINGOS et al., 2015).

A classificação de imagens é uma técnica que pode ser aplicada na análise de rugas para identificar e categorizar diferentes tipos de rugas em imagens da pele. Isso pode ser realizado usando algoritmos de classificação supervisionados ou não supervisionados.

Os algoritmos de classificação supervisionados, por exemplo, precisam ser treinados com exemplos de imagens de rugas já classificadas. A partir daí, o algoritmo é capaz de classificar automaticamente novas imagens de rugas de acordo com as categorias previamente definidas.

Já os algoritmos de classificação não supervisionados não precisam ser treinados com imagens previamente classificadas. Em vez disso, eles exploram as características intrínsecas da imagem para identificar padrões e categorizar de forma automática.

Esta abordagem de classificação de imagens pode ser útil para quantificar o grau de rugas e sua distribuição na pele, ajudando na avaliação do estado de envelhecimento da pele e na monitoração da eficácia de tratamentos antienvelhecimento. Além disso, a classificação de rugas também pode ser útil na pesquisa clínica, permitindo a comparação de resultados entre diferentes grupos de pacientes ou a avaliação da evolução da pele ao longo do tempo.


3.7. Redes neurais convolucionais

O aprendizado de máquina é um subcampo da inteligência artificial que se concentra em criar sistemas capazes de aprender a partir de dados, sem serem explícita ou detalhadamente programados. O objetivo é desenvolver algoritmos que possam realizar tarefas, como previsão, classificação, agrupamento, detecção de anomalias de forma

automática e precisa. Esse aprendizado é alimentado por dados, sendo que quanto mais dados um algoritmo tem disponível, mais preciso ele pode ser. As técnicas de aprendizado de máquina incluem métodos supervisionados, não supervisionados, semi-supervisionados e por reforço (LECUN et al., 2015).

As redes neurais são uma área de estudo dentro de aprendizado de máquina que busca imitar a forma como o cérebro humano funciona. Elas consistem em uma série de nós conectados, onde cada nó representa uma unidade de processamento de informação, que são os neurônios um exemplo pode ser verificado na Figura 4. A informação é transmitida através de conexões entre esses nós, e ao chegar em uma determinada saída, é aplicada uma função de ativação para decidir o resultado. As redes neurais são amplamente utilizadas em aplicações como reconhecimento de imagem, processamento de linguagem natural, análise de sentimentos, entre outros. Existem vários tipos de redes neurais, incluindo redes feedforward, redes recorrentes e redes neurais convolucionais.

Figura 4 - Representação de um neurônio




Fonte: Baheti (2023)

Uma rede neural possui diferentes tipos de camadas que variam de acordo com a aplicação, um exemplo de rede neural pode ser verificado na Figura 5. O treinamento de uma rede neural envolve apresentar vários exemplos de entrada e suas respectivas saídas

desejadas, e ajustar os pesos das conexões para que a rede produza resultados cada vez mais precisos. Esse processo é conhecido como otimização de perda e geralmente é realizado utilizando algoritmos de otimização, como o gradiente descendente.

Figura 5 - Representação de uma rede neural com três camadas



Fonte: Baheti (2023)

Já as Redes Neurais Convolucionais (Convolutional Neural Networks - CNNs) são uma arquitetura de redes neurais, que são especialmente projetados para processamento de imagens. Elas têm sido amplamente utilizadas na área de Visão Computacional para tarefas como classificação, segmentação e detecção de objetos. A principal ideia por trás das CNNs é que as características relevantes de uma imagem são identificadas através de várias camadas de filtros e pooling, que são aplicados à imagem original. Cada camada é responsável por extrair uma representação hierárquica das características da imagem. A última camada é uma camada totalmente conectada que é utilizada para a classificação da imagem. As CNNs são treinadas em grandes conjuntos de dados etiquetados, o que permite que elas aprendam a identificar padrões e características importantes em imagens. O treinamento é realizado através do ajuste dos pesos dos filtros e da camada totalmente

conectada, de modo que a saída da rede seja uma classificação precisa da imagem (KRIZHEVSKY et al., 2017).

As CNNs são uma forma poderosa de aprendizado profundo para resolver muitos problemas de processamento de imagens, no entanto, elas também apresentam algumas limitações, dentre as quais podem ser citadas:

- Complexidade computacional: CNNs são geralmente grandes em termos de número de parâmetros e, portanto, exigem muito poder de processamento para se treinar e executar. Além disso, o tempo de treinamento de uma rede neural pode ser bastante longo.
- Overfitting: As CNNs podem facilmente sobre ajustar seus dados de treinamento, o que significa que elas podem aprender ruído e outros detalhes irrelevantes ao invés de padrões gerais.
- Dificuldade de interpretação: Embora as CNNs sejam eficazes em classificação de imagens, elas são difíceis de interpretar. É difícil compreender como a rede está chegando a uma determinada classificação ou previsão.
- Sensibilidade às pequenas variações: As CNNs são sensíveis a pequenas variações na entrada, o que pode afetar sua precisão. Isso pode ser um problema em aplicações como a classificação de imagens médicas, onde pequenas variações podem ser importantes.
- Dificuldade em lidar com imagens desfocadas ou com ruído: As CNNs podem ter dificuldade em lidar com imagens desfocadas ou com ruído, pois são projetadas para funcionar com imagens claras e de alta qualidade.


Estas limitações devem ser consideradas quando se escolhe utilizar uma rede neural convolucional para uma tarefa específica. As principais ferramentas de software para utilização de redes neurais convolucionais (CNNs) incluem:

- TensorFlow: É uma plataforma de código aberto para desenvolvimento de modelos de aprendizado de máquina, com suporte para a criação de CNNs.
- PyTorch: É outra plataforma de código aberto para desenvolvimento de modelos de aprendizado de máquina, com suporte para a criação de CNNs.
- Keras: É uma biblioteca de código aberto para a criação de modelos de aprendizado de máquina baseados em redes neurais, incluindo CNNs.

- Caffe: É uma plataforma de código aberto para desenvolvimento de modelos de aprendizado de máquina, com suporte para a criação de CNNs. É conhecido por sua velocidade e capacidade de processamento em larga escala.

É importante escolher a ferramenta de software que melhor atenda às necessidades e preferências. Uma ilustração das camadas de uma CNN para classificação de imagens pode ser verificada na Figura 6.

Figura 6 - Representação de uma CNN para classificação de imagem



Fonte: Saha (2018)

Como as CNNs são dependentes do número de dados utilizados em seu treinamento, uma técnica utilizada para se aumentar a quantidade de dados a partir de um grupo de imagens inicial é a técnica de Image Augmentation, que é uma técnica de pré-processamento de imagem utilizada em aprendizado de máquina para aumentar o tamanho da base de dados. Isso é importante para evitar overfitting, que ocorre quando o modelo se ajusta muito bem aos dados de treinamento, mas não generaliza bem para dados novos ou não vistos. Essa técnica envolve a modificação artificial das imagens existentes, por exemplo, rotação, ampliação e escala. As novas imagens criadas são usadas para complementar a base de dados original. Ao se aplicar a técnica de image augmentation a CNNs, é possível aumentar a quantidade de dados de treinamento, ajudando a modelar a variabilidade e a robustez do modelo. Além disso, ao fazer uma ampla variedade de modificações nas imagens, é possível aumentar a capacidade do modelo de lidar com imagens com diferentes orientações e perspectivas. Há vários estudos que demonstram que o uso de image augmentation em conjunto com CNNs melhora o desempenho em

tarefas de classificação de imagem, como a detecção de objetos, análise de textura e segmentação.

Uma vez que uma CNN é treinada, faz-se necessária a realização de uma verificação do treinamento, isso pode ser realizado através de algumas métricas. As métricas utilizadas para avaliar a performance de CNNs incluem:

- **Acurácia:** a porcentagem de previsões corretas feitas pela rede. É a métrica mais comumente usada, mas pode ser enganosa em casos de desbalanceamento de classes.
- **Matriz de confusão:** uma tabela que mostra as previsões corretas e incorretas da rede para cada classe. Pode ser útil para entender melhor como a rede está se saindo em relação a cada classe.
- **Precisão:** a proporção de previsões corretas positivas em relação ao total de previsões positivas.
- **Recall:** a proporção de previsões corretas positivas em relação ao número total de instâncias positivas na base de dados.
- **F1-Score:** a média harmônica entre precisão e recall. É uma boa métrica quando há desbalanceamento de classes na base de dados.
- **AUC-ROC Curve:** a área sob a curva ROC, que compara a taxa de verdadeiros positivos (TPR) com a taxa de falsos positivos (FPR). É uma métrica útil para problemas de classificação binária.

Estas são apenas algumas das métricas mais comuns utilizadas para avaliar o desempenho de redes neurais convolucionais. É importante escolher as métricas adequadas para o problema em questão e levar em consideração o contexto para interpretar corretamente os resultados.

Existem diversos estudos na literatura que utilizam redes neurais convolucionais (CNNs) para a análise de rugas na pele. Essas técnicas têm sido amplamente utilizadas para quantificar e caracterizar o envelhecimento da pele, incluindo a avaliação da profundidade, da área e da distribuição das rugas. Alguns estudos também utilizam CNNs para detectar mudanças na pele ao longo do tempo, para avaliar o efeito de tratamentos anti-envelhecimento e para prever o envelhecimento futuro (ZHANG et al., 2017).

4 METODOLOGIA

4.1 Tipo de Estudo

Trata-se de um estudo clínico multicêntrico (Universidade Brasil-SP, DermoProbes e MEDCIN), comparativo, randomizado e instrumental, com abordagem quantitativa e qualitativa envolvendo seres humanos.

4.2 Aspectos éticos e legais

A presente pesquisa, por se tratar de uma pesquisa que envolve seres humanos, os seus aspectos éticos e legais atenderam a resolução N^o 466, de 12 de dezembro de 2012, considerando que todo o progresso e seu avanço devem sempre respeitar a dignidade, a liberdade e a autonomia do ser humano.

Foi explicado a todos os participantes o teor da pesquisa podendo eles manifestarem-se de forma autônoma, consciente, livre e esclarecida.

A pesquisa foi realizada em duas etapas com diferente número de participantes, logo foi necessária a autorização das duas etapas pelo comitê de ética em pesquisa. Cada etapa foi realizada após foi realizada a submissão na Plataforma Brasil, seguida da aprovação pelo comitê de ética e pesquisa da Universidade Brasil sob o número: 5.223.305 e pelo comitê de ética e pesquisa da Universidade São Francisco sob o número: 5.713.173.

4.3 Local da Pesquisa

A coleta de dados e imagens foi realizada nas empresas DermoProbes e MEDCIN após as devidas autorizações dos CEPs. Toda a etapa de processamento, análise de dados e desenvolvimento de software foram realizados no Laboratório de Espectroscopia Vibracional Biomédica da Universidade Brasil e na empresa DermoProbes.

O trabalho foi realizado de acordo com o cronograma estabelecido e obedecendo as etapas a seguir: coleta de dados, análise de dados, desenvolvimento de algoritmos, testes e validação e por fim análises estatísticas.

4.4 Seleção de Voluntários da Pesquisa

Na primeira fase do estudo, foram selecionados 90 participantes de pesquisa com diferentes graus de rugas, segundo os critérios de inclusão pré-estabelecidos.

Na segunda fase foram selecionados 33 participantes de pesquisa que participaram do estudo que realizou a verificação da pele antes e após a utilização de um produto dermocosmético.

4.5 Instrumentos utilizados

Os experimentos foram realizados utilizando-se a coleta de imagens com três diferentes dispositivos: Câmera de alta resolução, Sistema PRIMOS® e Dispositivo Dermatoscópico USB.

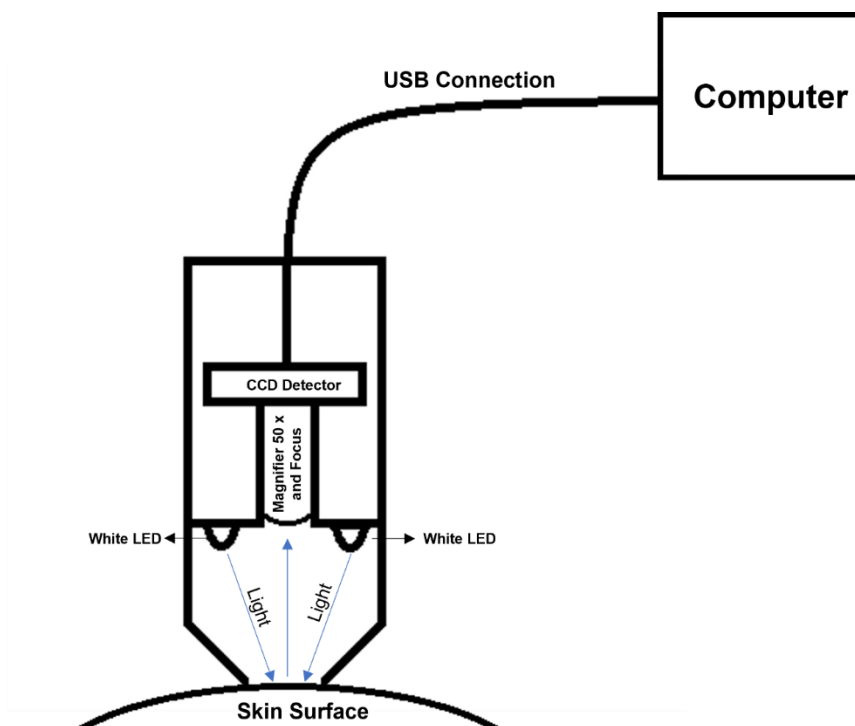
4.5.1 Câmera de alta resolução

Nos estudos realizados, foram coletadas imagens de alta resolução com uma câmera digital modelo Canon, essas imagens são utilizadas na documentação do projeto pelas empresas parceiras na realização do estudo clínico.

4.5.2 Dispositivo Dermatoscópico USB

A empresa Chemyunion Inc, como patrocinadora do projeto forneceu o dispositivo dermatoscópico utilizado no estudo. Esse dispositivo consiste basicamente de uma câmera USB com uma lente com magnificação óptica de 50 vezes, em conjunto com um sistema de iluminação composto com LEDs de alto brilho que fazem a iluminação do ponto focal onde a imagem é obtida. O dispositivo possui uma câmara escura com a abertura no ponto onde a região da pele deve ser posicionada, a ativação dos leds de alto brilho na direção da pele, faz com que ela seja iluminada e a luz seja capturada pela lente de aumento, essa luz então é direcionada para o detector CCD que faz a captura da imagem que por sua vez, através de um circuito eletrônico específico disponibiliza essas imagens através da conexão USB. A resolução das imagens fornecidas pelo dispositivo é de 1600 x 1200 pixels, capaz de cobrir uma área de 7 mm x 6.5 mm da pele. Uma ilustração das partes e modo de funcionamento do dispositivo pode ser verificada na Figura 7, na Figura 8 pode-se verificar o dispositivo.

Figura 7 – Esquema representando as partes que compõe o dermatoscópio USB



Fonte: Autoria própria

Figura 8 – Dispositivo dermatoscópio USB



Fonte: Chemyunion, 2022

4.5.3 Sistema PRIMOS®

O sistema PRIMOS® é considerado o dispositivo padrão-ouro a ser utilizado nas análises de relevo cutâneo, com diversas publicações científicas e estudos clínicos realizados utilizando-se dos parâmetros fornecidos por esse instrumento. O modo de funcionamento do PRIMOS® é conhecido como projeção de Fringe, que basicamente consiste na utilização de micro espelhos que alteram o direcionamento da luz e coleta a luz refletida em diferentes momentos, essa diferença de incidência é capaz de caracterizar um relevo. Esse dispositivo pode ser verificado na Figura 9. O sistema utilizado é de propriedade da MEDCIN.

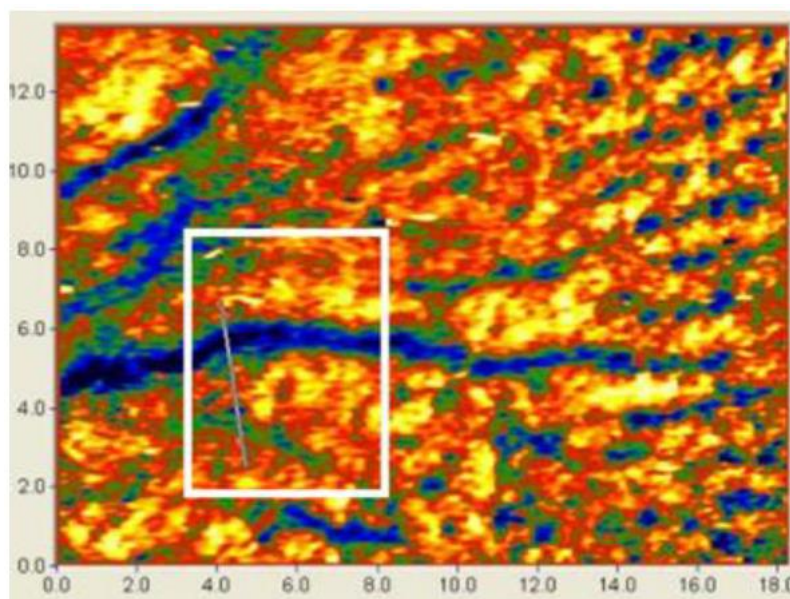
Figura 9 – Sistema PRIMOS®



Fonte: Canfield, 2022

Após a coleta de imagens com o PRIMOS®, é realizada a análise em seu software específico, em que o operador pode delimitar a região de interesse, no caso identificando os pontos de rugas, um exemplo de análise pode ser verificado na Figura 10, onde é possível identificar a região de análise.

Figura 10 – Imagem obtida pelo sistema PRIMOS® aberto no software de análise



Fonte: MEDCIN, 2022

4.6 Coleta de dados

A coleta de imagens foi realizada utilizando-se ambos os sistemas, PRIMOS® e dermatoscópio USB, levando-se em consideração a região periorbital, que é a área lateral ao olho e pode ser verificada na Figura 11. Conforme mencionado é uma região de grande evidência de rugas.

Figura 11 – Região periorbital analisada



Fonte: Autoria própria

4.6.1 Fase 1

Na fase 1, foi realizada apenas 1 visita ao centro de estudos para a coleta das imagens para construção de um banco de dados objetivando a tarefa de classificação de tipos de rugas por diferentes técnicas.

4.6.2 Fase 2

Já na fase 2, os participantes realizaram duas visitas ao centro de estudos, a primeira visita sendo correspondente a medida basal (D0), após a primeira visita, cada participante levou um dermocosmético antienvelhecimento e as devidas instruções de utilização pelo período de 45 dias, após esse tempo retornaram ao centro de estudos para a segunda coleta (D45). O estudo da fase 2 consistiu na realização de um estudo em que pudesse ser verificado parâmetros quantitativos das imagens obtidas pelo dermatoscópio USB.

4.7 Processamento de imagens

O processamento de imagens foi realizado utilizando-se a linguagem de programação Python, em conjunto com a biblioteca de visão computacional OpenCv. Diferentes filtros e operações matemáticas foram realizadas com o objetivo de se destacar características das imagens, principalmente rugas.

4.7.1 Imagens de treino CNN

As imagens obtidas pelo dermatoscópio USB na fase 1 do estudo passaram por etapas de pré-processamento para que pudessem ser utilizadas como imagens base de treinamento da rede neural convolucional, essas imagens foram divididas em grupos de acordo com o nível de rugas, essa separação foi realizada através da análise das informações fornecidas pelo sistema PRIMOS®, mais especificamente o Ra. Foram definidos quatro grupos de maneira tal que possam ser evidenciadas diferenças segundo a escala de Glogau. Do total de imagens, 10% das imagens de cada grupo foram removidas aleatoriamente para a formação de um conjunto de imagens de teste para validação do treinamento. Para cada um dos grupos, tanto de treino quanto de testes, foi aplicada a técnica de Image Augmentation, com a finalidade de se aumentar a quantidade de exemplos em cada grupo para maior acurácia do treinamento da rede.

4.7.2 Imagens para extração de características

Já para as imagens obtidas na fase 2, com o foco na obtenção de valores quantitativos, foram realizados processamentos e proposta uma metodologia para a segmentação da imagem com o objetivo de se evidenciar as regiões referentes a rugas.

4.8 Análise estatística

Na análise dos dados obtidos, foi verificada a normalidade dos dados utilizando-se o teste de Shapiro-Wilk, para a parte de comparativo entre os diferentes grupos para verificação da existência de diferença estatística significativa, foram utilizados o teste t para amostras nos grupos que apresentaram distribuição normal e o teste de Wilcoxon para amostras não paramétricas. Na análise de correlação foi aplicada a análise de correlação de Spearman, verificando-se o valor da correlação e o valor p da probabilidade de correlação, os valores fornecidos por essa análise são o coeficiente R e o valor p, em que o valor R varia de -1 a 1 e indica a força da correlação, que pode ser positiva ou negativa, valores de R de 0 a 0.19 indicam uma correlação muito fraca, de 0.2 a 0.39 uma correlação fraca, de 0.4 a 0.69 uma correlação moderada, de 0.7 a 0.89 uma correlação forte e por fim de 0.9 a 1 uma correlação muito forte (SCHÖBER et al 2018), já o valor de p verifica a hipótese nula de que não existe correlação entre os conjuntos de dados, logo se o valor de p for menor que 0.05, rejeita-se a hipótese nula, ou seja existe correlação entre os conjuntos de dados. Em toda a análise estatística, foi utilizado o nível de significância de 95%.

Com relação a verificação do treinamento da rede neural convolucional, utilizou-se a métrica da acurácia.

5 RESULTADOS

5.1 Classificação de Rugas

A classificação de rugas, visa majoritariamente a realização de uma análise em que dada uma nova imagem, o sistema seja capaz de classificá-la de acordo com o nível de rugas, da mesma maneira que uma avaliação segundo a escala de Glogau realizada por um profissional treinado fornece.


5.1.1 Pré-processamento de imagens

Foram realizadas etapas de pré-processamento das imagens, com o objetivo de se evidenciar características que se mostrassem importantes no treinamento da rede neural. Dentre os algoritmos aplicados, destacam-se a normalização da imagem, mapas de cor, operações lógicas e detecção de bordas. Todas essas etapas de pré-processamento foram realizadas utilizando-se a conversão da imagem original para a escala de cinza, uma vez que essa conversão simplifica o processamento, além de torná-lo mais preciso e compatível com a maioria das técnicas de visão computacional.

A etapa de normalização da imagem tem como objetivo de ajustar o brilho e o contraste da imagem para que seus valores de intensidade estejam dentro de um determinado intervalo, nesse trabalho foi aplicada a técnica de normalização do histograma, essa normalização ajuda a destacar características da imagem, a Figura 12 mostra uma imagem original obtida pelo dispositivo dermatoscópio USB e o resultado da normalização.

Figura 12 – Imagem obtida pelo dispositivo dermatoscópio:


Imagem original (A) e imagem normalizada (B)



Fonte: Autoria própria

A partir da imagem normalizada, foi realizada a aplicação de um mapa de cores disponível na biblioteca OpenCV, com o esquema de cores composto por uma combinação de cores que vão desde o azul escuro, passando pelo verde e amarelo até o vermelho escuro. Isso permite uma boa visualização de variações em dados que vão desde valores baixos até valores elevados, nesse caso a partir dos valores de escala de cinza presentes na imagem normalizada. O resultado da aplicação do mapa de cores pode ser visualizado na Figura 13.


Figura 13 – Imagem original (A) e imagem com a aplicação do mapa de cores (B)



Fonte: Autoria própria

Foram realizadas operações lógicas entre a imagem resultante do mapa de cores e a imagem original em escala de cinza, as operações realizadas foram AND, NOT, OR e XOR, os resultados obtidos podem ser verificados na Figura 14.

Figura 14 – Imagens processadas com operações lógicas AND (A), NOT (B), OR (C) e XOR (D)




Fonte: Autoria própria

5.1.1 Separação de grupos para treinamento da CNN

A separação das imagens em grupos foi realizada a partir da análise dos dados obtidos pelo sistema PRIMOS®, foi realizada uma análise utilizando-se estatística multivariada verificando-se simultaneamente dois parâmetros fornecidos, a média de profundidade de rugas e a rugosidade média Ra.

A primeira abordagem foi a realização da análise de agrupamento hierárquico, o resultado obtido pode ser verificado no dendrograma da Figura 15, analisando-se esse resultado, percebe-se a formação de muitos braços, acima do número de grupos preconizados segundo a escala de Glogau.

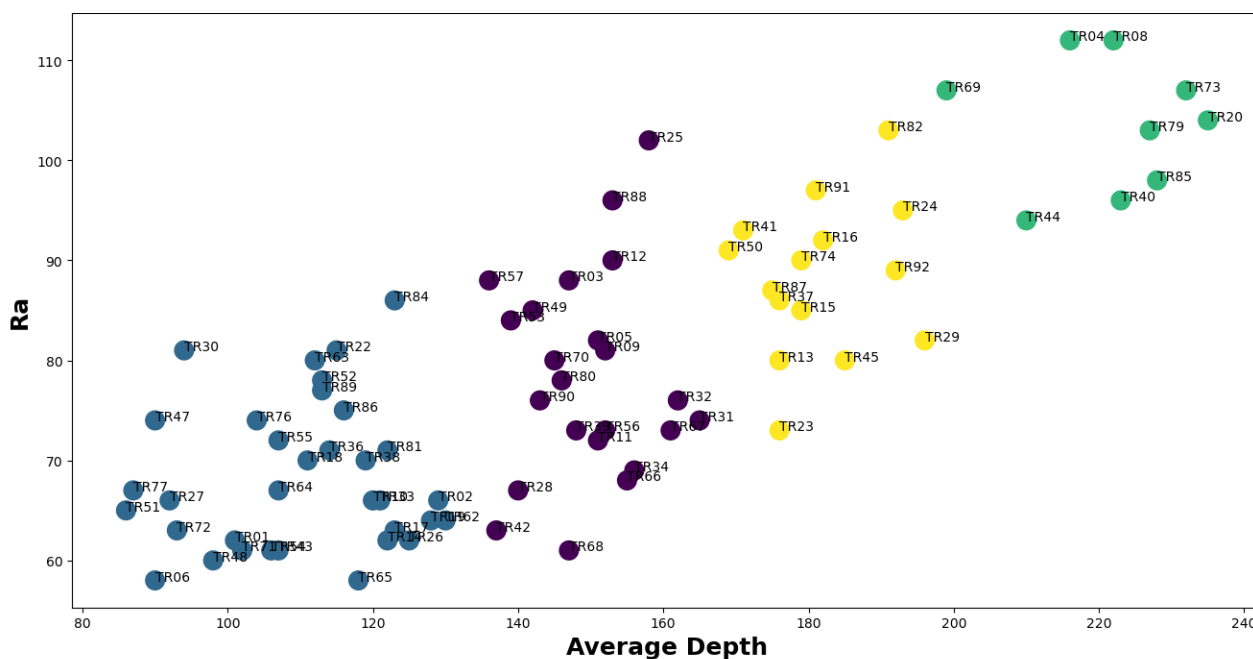
Figura 15 – Dendrograma analisando resultados obtidos pelo sistema PRIMOS®



Fonte: Autoria própria

Com isso, optou-se pela aplicação do algoritmo do K-ézimo vizinho mais próximo (K nearest neighbour - kNN), utilizando-se o número de grupos igual a 4, realizou-se a verificação das imagens pertencentes a cada grupo, conforme pode ser visualizado na Figura 16.


Figura 16 – Resultados do kNN



Fonte: Autoria própria


Para verificação da dispersão dos valores de Ra em cada um dos grupos, foi realizada uma análise de boxplot, conforme Figura 17, é possível verificar que o valor mediano do Ra aumenta conforme o grupo, sendo o grupo 1 classificado como ausência de rugas e o grupo 4 o de rugas mais profundas. Foi realizada a avaliação através de um histograma conforme demonstrado na Figura 18, onde verifica-se os quatro grupos.

Figura 17 – Boxplots representando a distribuição de valores de Ra nos quatro grupos definidos



Fonte: Autoria própria

Figura 18 – Histograma representando a distribuição de valores de Ra nos quatro grupos definidos



Fonte: Autoria própria

5.1.2 Arquitetura da CNN

A rede neural convolucional utilizada no projeto foi projetada e implementada utilizando-se as bibliotecas TensorFlow e Keras. O modelo da rede foi concebido para receber como entrada imagens de resolução 200 x 150 pixels e 3 canais de cores (RGB). O modelo possui implementação sequencial de diferentes camadas, composto por três camadas de Convolução, três camadas MaxPooling, duas camadas densas, uma camada de Dropout e uma camada Flatten, as funções de cada uma dessas camadas é descrita na sequência.

- **Convolução:** é a camada responsável por extrair características da entrada ao aplicar filtros diferentes sobre a informação de entrada, nesse caso imagens. Cada filtro é composto por pesos que são aprendidos durante o treinamento da rede. Quando o filtro é aplicado à entrada, ele produz uma saída, que é uma representação das características da entrada naquela região. Esses filtros são movidos para cobrir toda a entrada e extrair diferentes características em diferentes regiões, ela permite que a rede aprenda representações hierárquicas de características, como bordas, e formas.
- **MaxPooling:** é uma camada de subamostragem, realiza a divisão da entrada em janelas, selecionando o elemento mais importante como a representação para aquela região. O principal objetivo é reduzir o tamanho da representação da entrada, o que ajuda a reduzir o número de parâmetros na rede e a evitar o overfitting. Além disso, também é útil para tornar a rede mais robusta a variações nas posições das características na entrada, pois mesmo que a característica se mova, a representação selecionada para aquela janela será a mesma.
- **Dense:** também conhecida como camada totalmente conectada, é chamada de "dense" porque todos os neurônios na camada anterior estão conectados a todos os neurônios na camada atual. Sua utilização é aplicada para transformar as representações aprendidas nas camadas anteriores em uma representação final que pode ser usada para fazer uma previsão ou classificação.
- **Dropout:** funciona selecionando aleatoriamente alguns neurônios da camada anterior e descartando-os durante a passagem da informação para a camada


seguinte. Isso força a rede a aprender múltiplas representações para a mesma entrada, o que ajuda a tornar a rede mais robusta e generalizável.

- Flatten: camada responsável pela conversão de matrizes em vetores unidimensionais

Além das camadas, têm-se entre elas funções de ativação, as funções aplicadas no modelo foram a ReLU (Rectified Linear Unit) e Softmax, a função ReLU verifica o valor de entrada e retorna ele mesmo caso seja positivo e zero caso seja negativo, já a função Softmax retorna um vetor de probabilidades de pertencimento a determinado grupo. No modelo proposto a função Softmax foi aplicada como saída final da rede, retornando um vetor de 4 posições com as respectivas probabilidades de pertencimento a determinado grupo.


Um diagrama descritivo do modelo proposto pode ser visualizado na Figura 19 e um diagrama ilustrativo pode ser visualizado na Figura 20.

Figura 19 – Descrição do modelo proposto



Fonte: Autoria própria

Figura 20 – Visualização 3D das camadas da rede



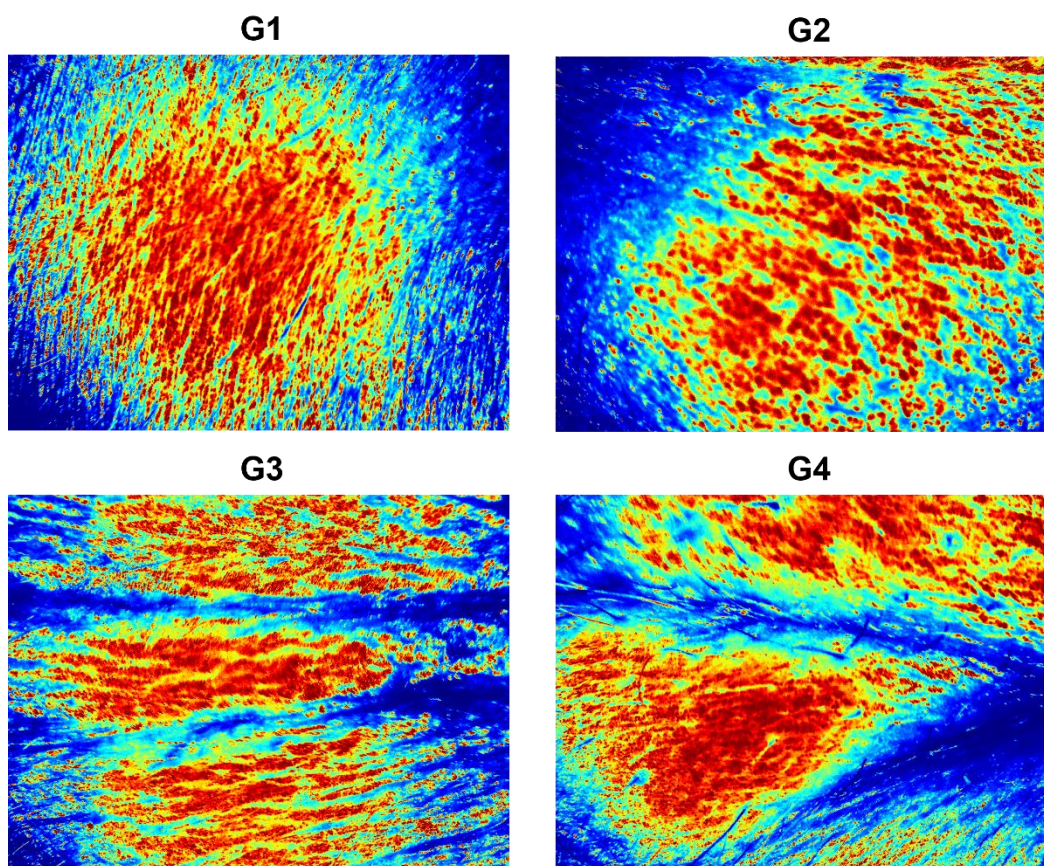
Fonte: Autoria própria

5.1.3 Treinamento da CNN

Foi estabelecido para o treinamento da rede neural, um total de 200 épocas, com o ajuste de pesos na rede dados os dados de treinamento previamente estabelecidos. Foram realizados treinamentos com os grupos de imagens normalizadas em escala de cinza e com as imagens com o filtro de mapa de cores aplicados. Um exemplo de cada imagem por grupo de treinamento pode ser visualizado na Figura 21, demonstrando características de cada um dos grupos.

O tempo de treinamento do modelo, utilizando-se um computador com processador Intel Core i7 de 7ª geração foi de aproximadamente 7,5 horas para cada um dos grupos de imagens avaliados. Cada modelo foi salvo para posterior avaliação do modelo.

Figura 21 – Exemplos de imagens em cada grupo de treinamento da CNN



Fonte: Autoria própria

5.1.4 Avaliação da CNN

Na avaliação do treinamento da rede neural, foi verificado o valor da acurácia, para os grupos de imagens normalizadas em escala de cinza, o maior valor da acurácia foi de 30,04% valor muito baixo que não é capaz de classificar corretamente uma nova imagem no seu grupo característico.

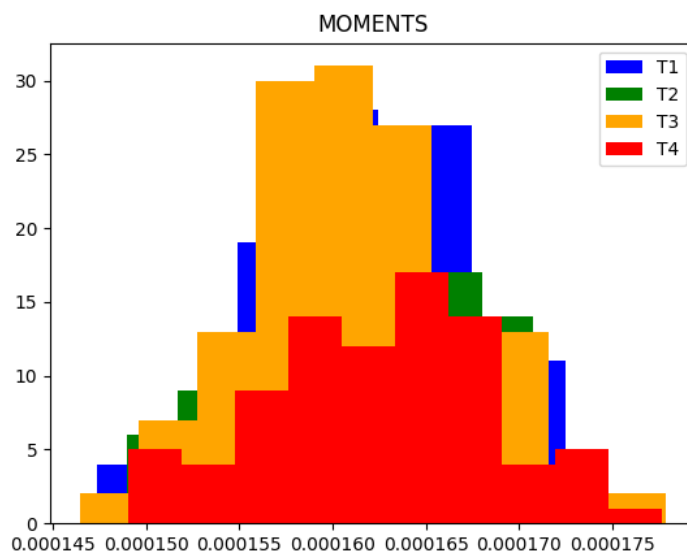
Já para o modelo treinado com o grupo de imagens com a aplicação do mapa de cores, foi obtido um valor de acurácia de 78,5%, valor considerado aceitável, uma vez que o modelo lida apenas com quatro grupos de imagens.

5.1.5 Análises complementares

Com a finalidade de se complementar as informações fornecidas pela classificação da rede neural, foi realizada uma análise de parâmetros da imagem que pudessem representar uma separação de grupos, os parâmetros escolhidos foram o momento,

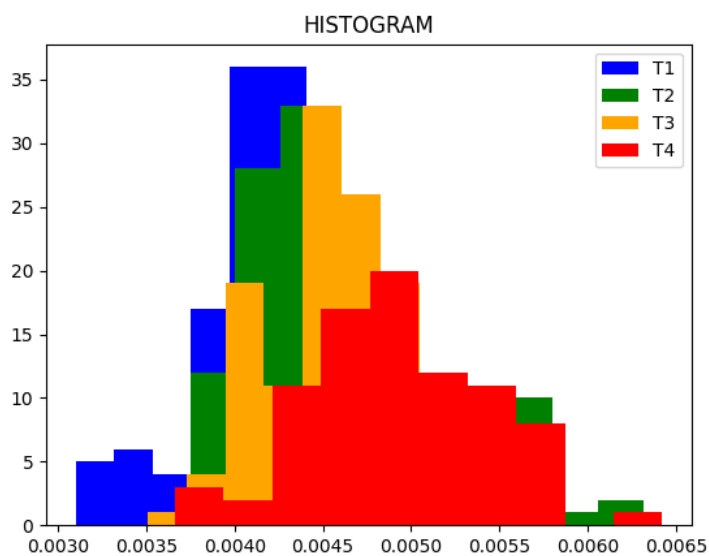
histograma e textura. Foram calculados os valores referentes a cada imagem obtida na fase 1 para cada grupo previamente separado, e verificada como se comportava a distribuição dos mesmos. As Figuras 22, 23 e 24 mostram a distribuição desses valores para cada parâmetro.

Figura 22 – Distribuição dos valores relativos ao cálculo de momento da imagem



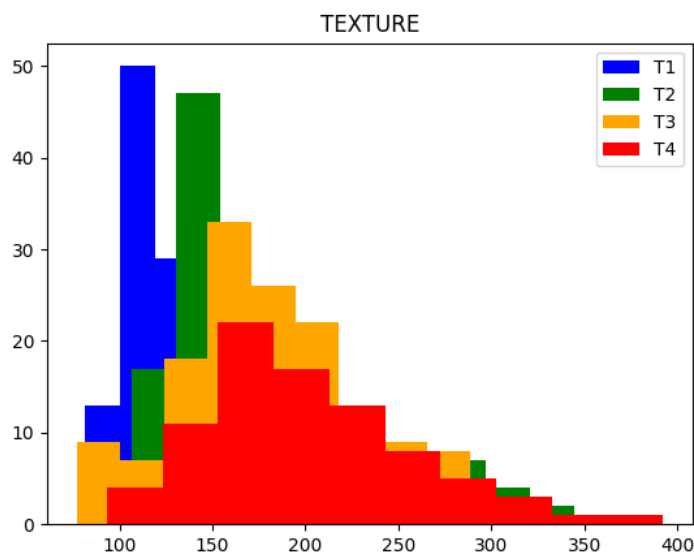
Fonte: Autoria própria

Figura 23 – Distribuição dos valores relativos à média do histograma das imagens



Fonte: Autoria própria

Figura 24 – Distribuição dos valores relativos ao cálculo da textura de cada imagem



Fonte: Autoria própria

Nos gráficos é possível verificar uma grande interseção entre os grupos, o que não representa diferenças estatísticas significativas. Porém na análise do parâmetro Textura, é possível verificar uma tendência no valor mediano, logo foi realizado o cálculo da mediana para cada um dos grupos e apresentado na Tabela 2.


Tabela 2 – Parâmetros fornecidos pelo sistema PRIMOS®

Tipo de ruga	Mediana
Tipo 1	130
Tipo 2	157
Tipo 3	174
Tipo 4	197

Fonte: Autoria própria.

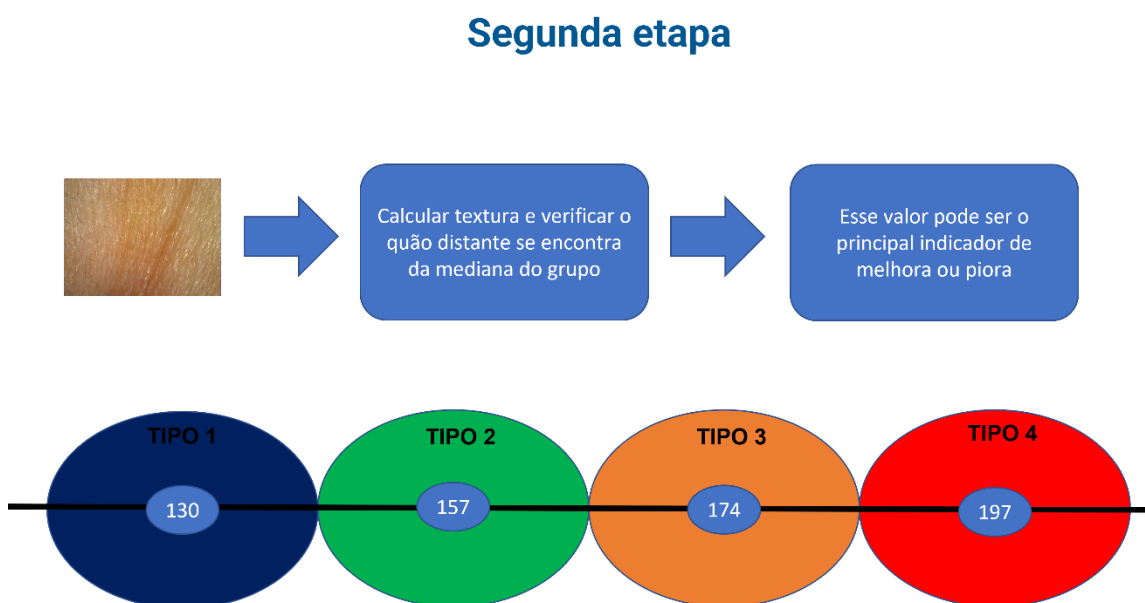
Com isso, foi verificada a possibilidade de uma informação complementar a classificação realizada pela rede neural, de maneira que após a classificação é possível verificar um valor quantitativo referente a cada grupo, sendo o algoritmo dividido em duas etapas conforme exemplificação nas Figuras 25 e 26.

Figura 25 – Primeira etapa da abordagem proposta, classificação via rede neural



Fonte: Autoria própria

Figura 26 – Etapa de quantificação da textura



Fonte: Autoria própria

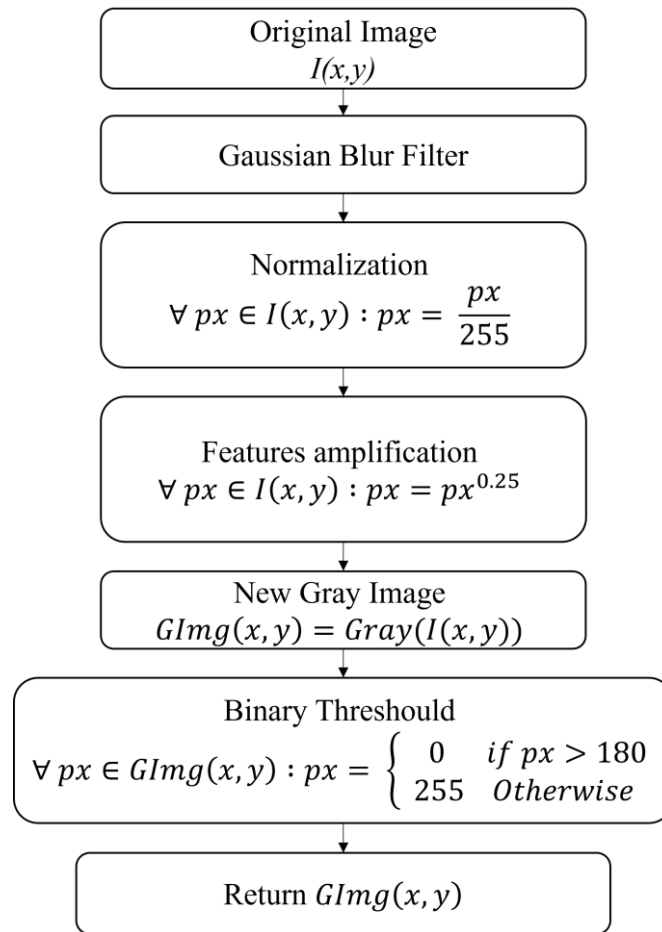
5.2 Análise quantitativa de rugas

Ainda que na etapa de classificação tenha sido verificada a possibilidade da utilização do valor de textura como uma medida quantitativa referente a ruga, não foi possível verificar uma correlação com o dispositivo PRIMOS®. Por essa razão, foi realizada a segunda fase do projeto com a avaliação de um estudo clínico do tipo antes e depois, com a coleta de informações tanto como o PRIMOS® quanto com o dermatoscópio USB. Nessa fase foram desenvolvidos algoritmos visando a busca por uma análise que tivesse correlação com o dispositivo padrão-ouro.

5.2.1 Segmentação da imagem

Nessa etapa, foi proposta a segmentação das áreas de rugas através da aplicação de filtros digitais e o desenvolvimento de um cálculo matemático que maximizasse as áreas de rugas. Nas imagens obtidas pelo dispositivo, é possível verificar que as regiões que representam as rugas apresentam-se de forma mais escura, uma vez que estando mais distante da fonte de luz, conseqüentemente a luz que retorna para a câmera nesses pixels é menor em relação as áreas que não são rugas e encontram-se mais próximas. Com essa informação, a primeira tentativa da determinação das áreas de ruga, foi apenas realizando a conversão da imagem original para escala de cinza, onde tem-se apenas um canal de cor de 16 bits, em que 0 representa preto e 255 o branco, com tons de cinza na variação entre esses extremos, a partir dessa imagem realizou-se a verificação do limiar, que acaba sendo dependente da tonalidade da pele analisada, bem como a quantidade de luz que foi capturada pela câmera. Com isso em vista, foi desenvolvido o algoritmo demonstrado na Figura 27.

Figura 27 – Algoritmo de segmentação de áreas de rugas



Fonte: Autoria própria

A primeira etapa do algoritmo proposto, consiste na aplicação de um filtro de desfoque gaussiano na imagem original utilizando-se um kernel de 37x37, o objetivo desse filtro é a homogeneização dos efeitos da luz na imagem e remoção de pequenos artefatos. A segunda etapa consiste na normalização da imagem numa escala de 0 a 1, para todos os canais, realizando-se a divisão de cada pixel pelo valor máximo de 255. A partir da imagem normalizada, é realizada a etapa aqui chamada de amplificação de características, que consiste basicamente na elevação de cada valor de pixel a um expoente, quanto menor o valor desse expoente, mais clara é a imagem resultante, a partir dos experimentos realizados, chegou-se ao valor de expoente igual a 0.25, que resulta em uma imagem em que os tons escuros se tornam ainda mais escuros, ou seja se aproximam de 0 e os tons mais claros se tornam ainda mais claros, aproximando-se de 1. Essa característica é desejada, uma vez que os pontos de interesse que são as rugas são determinados pelas

áreas escuras, que agora estão ainda mais destacadas. Nas imagens obtidas a partir pelo dispositivo, um ponto de atenção nos primeiros testes do algoritmo era a detecção de pelos como sendo rugas, uma vez que a difração da luz nesses elementos gera tonalidades semelhantes àquelas geradas pelas rugas, com a implementação da amplificação de características, os pelos deixaram de ser segmentados no resultado. Depois da amplificação de características, uma nova imagem é gerada na escala de cinza, como pode ser observada na Figura 28. Essa imagem então passa por um filtro binário de limiar, em que valores de pixel acima de 180 recebem o valor 0 e abaixo disso o valor 255, gerando assim uma imagem em preto e branco onde os pixels em branco representam as regiões correspondentes as rugas.

Figura 28 – Resultados da etapa de segmentação



Fonte: Autoria própria

Para verificação dos pontos identificados pelo algoritmo de segmentação, foi realizada a sobreposição da imagem segmentada na imagem original, para se verificar as regiões de rugas detectadas, conforme pode ser verificada na Figura 29.

Figura 29 – Imagem segmentada sobreposta a imagem original



Fonte: Autoria própria

É importante verificar que a segmentação proposta não identifica apenas as regiões mais profundas das rugas, porém abrange as regiões adjacentes nas bordas das rugas correspondentes a áreas mais rasas do vale até que se atinja o platô da pele.

5.2.2 Análise de Rugosidade

Como a pele humana também apresenta comportamento de irregularidades, esses parâmetros foram adaptados por diversos autores para se avaliar a rugosidade da pele, inclusive, o principal parâmetro fornecido pelo sistema PRIMOS® é a rugosidade média da região de interesse. Em imagens 2D como as obtidas pelo dispositivo microscópio aqui utilizado, não é possível ter-se a medida de profundidade em micrometros, porém é possível verificar diferentes tonalidades, com partes profundas apresentando-se mais escuras e áreas rasas mais claras. Tendo isso em vista, é proposta uma nova abordagem no cálculo da rugosidade média de uma imagem 2D, focando-se especialmente nas regiões que apresentam rugas, o método consiste basicamente em realizar o cálculo da rugosidade média a partir da imagem original convertida em escala de cinza, levando-se em consideração apenas pixels pertencentes a região de rugas detectada pelo algoritmo de detecção aqui apresentado, dividido pela área total da imagem, o valor de R_a é demonstrado na Eq. 1.

$$R_a = \frac{1}{wh} \sum_{i=0}^w \sum_{j=0}^h W_p(G(i,j)) \quad (1)$$

$$W_p(G(i,j)) = \begin{cases} G(i,j) & \text{if } G(i,j) \in \text{Wrinkle} \\ 0 & \text{Otherwise} \end{cases} \quad (2)$$

Com o valor w sendo a largura da imagem em número de pixels e h sendo a altura, $G(i,j)$ é a imagem original em escala de cinza. Para cada pixel, é analisado se este pertence ao grupo de pixels que compõe a área de rugas detectadas, essa avaliação é realizada

pela função W_p definida na Eq. 2, que retorna o valor do pixel em análise caso este pertença a área de rugas e 0 caso contrário.

No desenvolvimento, também foi realizada a implementação do cálculo de R_q de forma modificada com ênfase na área de rugas conforme descrito na Eq. 3, os parâmetros levados em consideração são os mesmos utilizados no cálculo do R_a .

$$R_q = \sqrt{\frac{\sum_{i=0}^w \sum_{j=0}^h (W_p(G(i,j)))^2}{wh}} \quad (3)$$

5.2.3 Área de Rugas


Como o tamanho total da imagem obtida pelo device em mm é conhecido, considerando-se que a resolução máxima da imagem obtida é de 1600x1200, foi possível a realização do cálculo da área relativa a cada pixel, que é de $0.203 \times 10^{-4} \text{ mm}^2$. Com isso foi possível a realização do cálculo do parâmetro área de rugas, que basicamente consiste na multiplicação da área de um pixel pela quantidade de pixels contidos no conjunto de pixels que se encontram na área de rugas, conforme descrito na Eq. 4.

$$W_a = \text{count}(px \in Wrinkles) * 0.203 * 10^{-4} \quad (4)$$

5.2.4 Valores obtidos

Nos testes dos algoritmos propostos, foram verificados os comportamentos da etapa de segmentação, bem como a quantificação. Na Figura 30 é possível verificar a região analisada no participante de pesquisa com ambos os dispositivos, e na Figura 31 é possível verificar exemplos de três diferentes graus de rugas, com a etapa de identificação da ruga e a quantificação dos parâmetros.

Figura 30 – Exemplo de análise, região periorbital (A), imagem PRIMOS® (B), imagem dermatoscópico (C) e resultado da segmentação (D)



Fonte: Autoria própria

Figura 31 – Exemplos de imagens processadas

Original Image	Wrinkle's area	Measured parameters
		Ra: 0.05 Rq: 2.35 Wa: 0.02 mm²
		Ra: 5.23 Rq: 23.92 Wa: 1.9 mm²
		Ra: 19.31 Rq: 47.23 Wa: 6.64 mm²

Fonte: Autoria própria

5.2.5 Comparação com PRIMOS®

A partir dos dados obtidos foi realizado o teste de normalidade para cada um dos conjuntos de dados, com a finalidade de se definir os testes estatísticos a serem aplicados nas diferentes comparações. A Tabela 3 mostra o resultado do teste de Shapiro para cada um dos conjuntos de dados. É possível verificar que o parâmetro Ra obtido pelo PRIMOS® e obtido pelo dermatoscópio apresentaram valores $p < 0.05$, não apresentando distribuição normal, já o parâmetro Rq obtido pelas imagens do dermatoscópio apresentaram distribuição normal em ambos os tempos.

Tabela 3 – Testes de normalidade para cada um dos parâmetros mensurados

SHAPIRO WILK NORMALITY TEST	
Parameter	<i>p-value</i>
Primos Ra D0	0.0071
Primos Ra D45	0.0074
Dermatoscopy Ra D0	0.0024
Dermatoscopy Ra D45	0.0437
Dermatoscopy Rq D0	0.1049
Dermatoscopy Rq D45	0.3881

pvalue < 0.05 rejects the null hypothesis that the distribution is normal

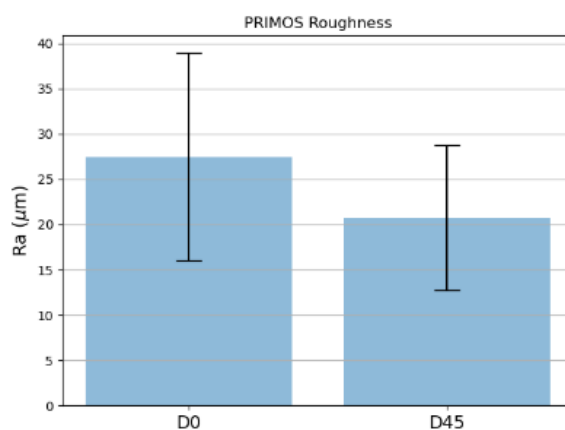
Fonte: Autoria própria

Com isso, foi realizada a análise de correlação de Spearman, verificando-se a correlação entre os valores obtidos pelo device em comparação com o PRIMOS® nos diferentes tempos, na comparação dos valores de Ra em D0, temos uma correlação fraca, com o coeficiente $R_s = 0.275$ e um valor $p = 0.19$ indicando que os dados não tiveram correlação em D0, essa baixa correlação é explicada pelo alto desvio padrão dos dados em ambas as medidas. Já na avaliação do parâmetro Ra nos dados obtidos após 45 dias, temos uma correlação moderada com o coeficiente $R_s = 0.47$ e valor $p = 0.018$ com forte evidência da correlação entre os parâmetros. Da mesma forma, foi realizada a avaliação do parâmetro Rq do dermatoscópio em comparação com o parâmetro Ra do PRIMOS®, na medida basal obteve-se novamente uma correlação fraca, com o coeficiente $R_s = 0.276$ e

valor $p = 0.19$, já nos dados após 45 dias, obteve-se uma correlação moderada com o coeficiente $R_s = 0.466$, porém com valor $p = 0.02$ indicando fortes indícios da correlação entre esses dois parâmetros.

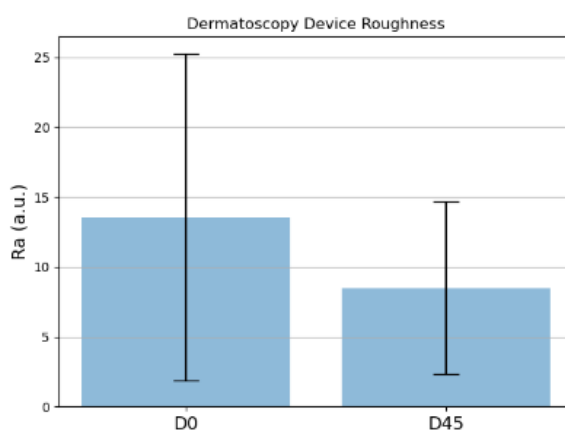
Nas Figuras 32, 33 e 34 são apresentados em gráficos de barras a comparação entre os dois tempos para cada um dos parâmetros analisados. É possível verificar nos três valores analisados, uma tendência de diminuição da rugosidade média após 45 dias de utilização do produto dermocosmético.

Figura 32 – Resultados Ra obtidos pelo sistema PRIMOS®



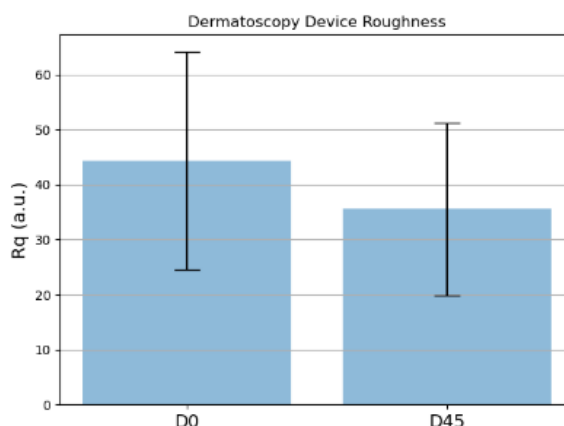
Fonte: Autoria própria

Figura 33 – Resultados Ra obtidos pelo sistema proposto



Fonte: Autoria própria

Figura 34 – Resultados Rq obtidos pelo sistema proposto



Fonte: Autoria própria

Foi realizada então a verificação da existência de significância estatística entre os dados obtidos no tempo D0 e D45, com a finalidade de se comprovar a eficácia do tratamento. Analisando-se o parâmetro Ra obtido pelo PRIMOS®, têm-se que o valor de $p = 0.000000119$, considerando-se um nível de significância de 95%, pela análise desse parâmetro rejeitamos a hipótese nula de que não houve diferença após o tratamento. Da mesma maneira, essa análise foi realizada para o parâmetro Ra proveniente das imagens do Dermatoscópio, têm-se que o valor de $p = 0.0229$, que assumindo-se uma significância de 95% também detectou que houve diferenças estatísticas significativas após a utilização do dermocosmético. Por fim, foi verificada a diferença entre os valores de Rq obtidos em D0 e D45, como esse conjunto de dados foi o único que apresentou distribuição normal, foi utilizado um teste t na comparação que apresentou um valor $p = 0.102$, que considerando-se 95% de significância, não foi capaz de detectar diferenças estatísticas significantes entre os tratamentos.

6 DISCUSSÃO

Verificando-se os resultados apresentados pela rede neural, uma acurácia de 78,5% é um resultado satisfatório, uma vez que ainda que tenha sido aplicada a técnica de *Image Augmentation*, o número de imagens disponíveis para o treinamento da rede é considerado baixo, além do desbalanceamento no número de exemplos de cada grupo, com o grupo 1 apresentando o maior número de imagens e o grupo 4 o menor, soma-se o fato de que as diferenças entre alguns grupos é de difícil percepção, tem-se que a rede é satisfatória na tarefa de classificação. Comparando-se com resultados da utilização de redes neurais convolucionais para o diagnóstico de doenças na pele, têm-se que Rathod (2019) obteve uma acurácia de 70% e Milton (2018) uma acurácia de 76%, ambos autores justificam a necessidade do aumento de exemplos de treino em seus respectivos bancos de dados.

Tendo em vista que o objetivo do sistema é ser aplicado em um software comercial, em que a base de usuários e coleta de informações tende a crescer, é possível a realização do aumento de imagens exemplos para cada grupo, com o intuito de se elevar a acurácia da rede.

A avaliação da textura da imagem é um fator que visa contribuir com uma informação adicional à classificação realizada pela rede neural, uma vez que esse valor pode indicar tendências, por exemplo se um tratamento dermatológico não foi suficiente para uma mudança de grupo, em uma avaliação antes e depois, o valor da textura pode ser utilizado como um parâmetro auxiliar nessa avaliação.

A análise quantitativa de valores que representem as características da ruga é crucial, uma vez que foi possível a comparação dos resultados apresentados pelo sistema aqui proposto com um dispositivo comercial e amplamente utilizado pela indústria dermatológica que é o sistema PRIMOS®. Como o principal parâmetro utilizado em avaliações realizadas com o sistema PRIMOS® é o valor da rugosidade média, o desenvolvimento do algoritmo deu-se de maneira guiada, porém verificando-se que no sistema proposto, o cálculo dos parâmetros da rugosidade média é realizado levando-se em consideração as regiões de pixels que realmente são classificadas como áreas de rugas, e não mais a rugosidade da imagem como um todo.

Na avaliação dos valores de Ra obtidos pelo PRIMOS® e pelo sistema proposto, percebe-se que ainda que o sistema PRIMOS® seja considerado o padrão-ouro nesse tipo de análise, este apresentou grande variabilidade nos dados obtidos tanto em D0 quanto em

D45, não apresentando uma distribuição normal dos dados, comportamento que também foi verificado pela análise das imagens obtidas pelo dispositivo dermatoscópio USB. Em ambos os casos a análise estatística demonstrou diferença significativa entre as medidas D0 e D45, confirmando que o produto dermocosmético teve efeito na melhora do relevo cutâneo.

Além do Ra, realizou-se da mesma maneira o cálculo do Rq, que demonstrou uma característica interessante de apresentar distribuição normal, ainda que na análise comparativa considerando-se um nível de significância de 95% não tenha apresentado diferença estatística significativa. Foi possível também a determinação da área de rugas, que pode ser um parâmetro a ser utilizado em avaliações clínicas como um complemento às análises de rugosidade.

Alguns aspectos do algoritmo proposto podem ser melhorados com a finalidade de obter uma maior correlação direta com os resultados apresentados pelo sistema PRIMOS®, porém com os resultados aqui apresentados é possível a utilização do sistema com validação científica.

7 CONCLUSÃO

O sistema proposto para a quantificação de rugas apresentou resultados compatíveis com o apresentado pelo sistema padrão-ouro. Este resultado sugere que o sistema proposto é uma alternativa viável aos sistemas existentes, oferecendo resultados semelhantes sem o alto custo associado aos sistemas padrão-ouro como o PRIMOS®.

Além disso, uma das principais vantagens do sistema é o seu baixo custo de implementação, tanto de software quanto de hardware, tornando-o uma opção atraente para muitas aplicações práticas. No futuro, esperamos continuar a aprimorar o nosso sistema e investigar aplicações adicionais em diferentes áreas.

Os resultados desta pesquisa são promissores e sugerem que a proposta é uma alternativa viável e acessível para a classificação e quantificação de rugas.

REFERÊNCIAS

- ALIBERT, JL. **Anatomy and Physiology of the Skin**. 1806.
- ALPAYDIN, E. **Introduction to machine learning** (2nd ed.). Cambridge, MA: MIT Press. 2010.
- ASKARULY et al., S. "**Quantitative Evaluation of Skin Surface Roughness Using Optical Coherence Tomography In Vivo**," IEEE Journal of Selected Topics in Quantum Electronics, vol. 25, no. 1, Oct. 2018.
- BATEMAN, T. **A Treatise on the Diseases of the Skin**. 1817.
- BAZZI, M. A. J. and EL-EMAM, M. "**Image Representation: A Review**", International Journal of Image and Graphics, 2011.
- BOISSY, R. E. **The evaluation of skin color**. Dermatologic Clinics, 17(4), 633-646. 1999.
- BOUWSTRA, J. A., & PONEC, M. **The biology of the skin stratum corneum**. Chemical Society Reviews, 26(4), 141-168. 1997.
- BRADSKI, G. "**The OpenCV Library**" Journal of Software Tools, 2000.
- CALLAHAN JG, et al. **Botulinum toxin type A for the treatment of glabellar lines: a systematic review**. Dermatol Surg. Apr;32(4):455-60. 2006.
- CHAUDHURI, S. S. and CHAUDHURI, B. B. "**Image Segmentation: A Literature Survey**", Pattern Recognition, vol. 31, no. 9, pp. 1335-1380, 1998.
- CULA et al., O. G. "**Assessing facial wrinkles: Automatic detection and quantification**," Skin Research and Technoly, vol. 19, no. 1, pp. 243–251, 2013.
- DOMINGOS, P. "**A Few Useful Things to Know About Machine Learning**". Communications of the ACM, 58(7), 78-87. 2015.
- DRAELOS ZD. **The role of diet and nutrition in preventing aging skin**. Clin Dermatol. Jul-Aug;28(4):409-13. 2010.
- DRAELOS, Z. D. **A review of skin moisturization**. Journal of Cosmetic Dermatology, 1(2), 75-82. 2002.
- DRAELOS, Z. D. **Color measurement of the skin**. Dermatologic Therapy, 20(4), 251-259. 2007.
- ESCALANTE, H. J. and PÉREZ, M. A. "**Digital Image Representation: A Survey**", Computer Science Review, 2013.

FARKAS, G. and DRÉGELYI-KISS, Á. "**Measurement uncertainty of surface roughness measurement**", XXIII International Conference on Manufacturing (Manufacturing 2018), pp. 448, 2018.

FERREIRA, M.R.P. "**Efficacy of anti-wrinkle products in skin surface appearance: a comparative study using non-invasive methods**" Skin Research and Technology, vol. 16, no. 4, pp. 444-449, Nov. 2010.

FITZPATRICK, T. B. "**Soleil et peau,**" Journal Médecine Esthétique, vol. 2, no. 1, pp. 33–34, 1975.

Geometrical Product Specifications (GPS) – **Surface Texture: Profile Method – Terms, Definitions and Surface Texture Parameters.** International Organisation for Standardization, Standard ISO 4287. 1998.

GLOGAU, R. G. "**Physiologic and Structural Changes Associated with Aging Skin**" Dermatologic Clinics, vol. 15, no. 1, pp. 555–559, Oct. 1997.

GOLDBERG DJ, et al. Non-ablative radiofrequency for skin rejuvenation. J Cosmet Laser Ther. Dec;8(4):187-91. 2006.

GOLDSBERRY et al A., "**VISIA system: a possible tool in the cosmetic practice,**" Journal of Drugs in Dermatology, vol. 13, no. 11, pp. 1312–1316, Nov. 2014.

GONZALEZ, R. C. and WOODS, R. E. "**Digital Image Processing**", 3rd Edition, Prentice Hall, 2008.

HACHEM, J. P., & GALLOIS, M. **Skin surface topography: a review of noninvasive techniques and applications in dermatology.** Journal of the European Academy of Dermatology and Venereology, 24(4), 333-343. 2010.

HASTIE, T., TIBSHIRANI, R., & FRIEDMAN, J. **The elements of statistical learning: Data mining, inference, and prediction** (2nd ed.). New York, NY: Springer. 2009.

HILLEBRAND GG, et al. **A review of skin surface analysis and its applications in dermatology.** Skin Res Technol. Feb;22(1):17-26. 2016.

JAIN, A. K. and DUBES, R. C. "**A Review of Image Segmentation Techniques**", Computer Vision, Graphics, and Image Processing, 1988.

JASPERS et al., S. "**Rapid in vivo measurement of the topography of human skin by active image triangulation using a digital micromirror device,**" Skin Research & Technology, vol. 5, no. 3, pp. 195–207, Aug. 1999.

JIANG, X. and LIAO, Q. "Skin wrinkles analysis based on digital image processing," presented at the 2012 Int. Conf. on Wavelet Active Media Technology and Information Processing (ICWAMTIP), Chengdu, China, Dec. 17-19, 2012.

KAFI R, et al. **The effect of lifestyle factors on the appearance of aging.** J Drugs Dermatol. Sep;10(9 Suppl):s2-11. 2011.

KALKA-MOLL, W. M., & STERRY, W. **Clinical and instrumental evaluation of skin ageing.** British Journal of Dermatology, 147(1), 9-19. 1992.

KIM et al. "**Automated wrinkle analysis using multi-scale fractal dimension.**" Computers in Biology and Medicine. 2017.

KIM et al. "**Quantitative assessment of wrinkle severity using texture analysis.**" Journal of Cosmetics, Dermatological Sciences and Applications. 2017.

KIM et al. "**Quantitative assessment of wrinkles using digital image analysis.**" Skin Research and Technology. 2017.

KIM J, et al. **A review of skin assessment tools.** J Eur Acad Dermatol Venereol. Oct;29(10):1843-54. 2015.

KIST, D. A., & KOSSARD, S. **Noninvasive evaluation of skin thickness.** Clinical, Cosmetic and Investigational Dermatology, 4, 19-25. 2011.

KOC, E., CIFTCI, R., & AKTAS, A. **A review of skin roughness measurements.** Journal of Cosmetic and Laser Therapy, 19(2), 108-115. 2017.

KOTTNER et al., J. "**Comparison of two in vivo measurements for skin surface topography**", Skin Research and Technology, vol. 19, no. 1, pp. 84–90, Nov. 2012.

KRIZHEVSKY, A. ILYA S., and GEOFFREY E. H. "**Imagenet classification with deep convolutional neural networks.**" In Advances in neural information processing systems, pp. 1097-1105. 2012.

LANGEVELD et al., M. "**Skin measurement devices to assess skin quality: A systematic review on reliability and validity,**" Skin Research & Technology, vol. 28, no. 2, pp. 212–224, Mar. 2022.

LECUN, Y. YOSHUA B., and GEOFFREY H. "**Deep learning.**" nature 521, no. 7553 :436-444. 2015.

LEMPERLE, G. "**A Classification of Facial Wrinkle,**" Plastic and Reconstructive Surgery, vol. 108, no. 6, pp. 1735–1750, Nov. 2001.

LIM JT, et al. **The importance of skin analysis in cosmetic dermatology.** J Cosmet Dermatol. Sep;5(3):220-6. 2006.

LIMPIANGKANAN, W. "**Photo-Aging: A Literature Review,**" Journal of Medical Association Thailand, vol. 93, no. 1, pp. 753–760, Jun. 2010.

LUEBBERDING, S. KRUEGER, N. and KERSCHER, M. "**Comparison of Validated Assessment Scales and 3D digital fringe projection method to assess lifetime development of wrinkles in men**" Skin Research and Technology, vol. 20, no. 1, pp. 753-760, Feb. 2014.

Milton, A. A. "**Automated Skin Lesion Classification Using Ensemble of Deep Neural Networks in ISIC 2018: Skin Lesion Analysis Towards Melanoma Detection Challenge**" International Skin Imaging Collaboration ISIC 2018.

NG et al., C. C. "**Automatic wrinkle detection using hybrid hessian filter**," in Proc. 12th Asian Conference Computer Vision, Springer International Publishing, pp. 609–622. 2014.

NG et al., C.-C. "**Wrinkle detection using hessian line tracking**," IEEE Access, vol. 3, pp. 1079–1088, 2015.

PARKER, J. R. "**Algorithms for Image Processing and Computer Vision**", John Wiley & Sons, 1997.

PITCHE, V., CHOUDHURY, M. R., & NAVE, R. "**A review of dermatoscopy for the assessment of cutaneous melanocytic lesions**." Journal of Cutaneous Pathology, 44(2), 123-131. 2017.

RATHOD J., WAZHMODE V., SODHA A., BHAVATHANKAR P. "**Diagnosis of skin diseases using convolutional neural networks**" 2018 Second International Conference on Electronics, Communication and Aerospace Technology, ICECA, IEEE (2018), pp. 1048-1051

REHMAN, M. and SHAH, A. A. "**A Review of Image Representation Techniques**", Journal of King Saud University - Computer and Information Sciences, 2012.

RENDON MI, et al. "**Topical retinoids in the treatment of photoaging**." J Am Acad Dermatol. Jul;61(1):125-43. 2009.

REW et al., J. "**Skin Aging Estimation Scheme Based on Lifestyle and Dermoscopy Image Analysis**," Applied Sciences, vol. 9, no. 6, p. 1228, Mar. 2019.

ROQUES et al., C. "**PRIMOS: an optical system that produces three-dimensional measurements of skin surfaces**," Journal of Wound Care, vol. 12, no. 9, Sep. 2013.

ROSENFELD, A. and KAK, A. C. "**Image Segmentation Using Markov Random Fields: A Review**", IEEE Transactions on Pattern Analysis and Machine Intelligence, 1982.

ROSSUM, G. "**Python tutorial**," Technical Report CS-R9526, Centrum voor Wiskunde en Informatica (CWI), Amsterdam, May 1995.

ROTHER, I. SUSSE, H. and VOSS, K. "**The method of normalization to determine invariants**," IEEE Trans. Pattern Anal. Mach. Intell., vol. 18, no. 4, pp. 366–376, Apr. 1996.

SAHA, S. K. and PAL, S. K. "**Image Segmentation Techniques: A Survey**" por International Journal of Computer Applications, 2010.

SARAVANAN, C. "**Color Image to Grayscale Image Conversion,**" presented at the 2010 Sec. Int. Conf. on Computer Engineering and Applications (ICCEA 2010), Bali Island, Indonesia, Mar. 19-21, 2010.

SATTLER G, et al. **Clinical evaluation of skin aging.** J Cosmet Dermatol. Sep;7(3):194-200. 2008.

SCHOBER, P. BOER, C. and SCHWART, L.A. "**Correlation Coefficients: Appropriate Use and Interpretation**" Anesthesia & Analgesia, vol. 126, no. 5, pp 1763-1768, May 2018.

SERUP, J. **Assessment of skin elasticity and viscoelastic properties.** Journal of the European Academy of Dermatology and Venereology, 1(2), 95-102. 1992.

SEZGIN, M. and SANKUR, B. "**Survey over image thresholding techniques and quantitative performance evaluation,**" Journal of Electronic Imaging, vol. 13, no. 1, Jan. 2004.

SHAPIRO, L. G. and STOCKMAN, G. C. "**Computer Vision**", pp 137-150. Prentice Hall, 2001.

SHAPIRO, S.S. and WILK, M.B. "**An analysis of variance test for normality (complete samples),**" Biometrika, vol. 52, pp.591-611, 1965.

SPEARMAN, C. "**The Proof and Measurement of Association between Two Things,**" Am. J. Psychol. vol. 15, pp. 72–101, 1904.

STUDENT, "**The probable error of a mean,**" Biometrika, pp.1–25, 1908.

SUPRIJANTO et al, S. "**Digital Dermatoscopy Method for Human Skin Roughness Analysis,**" Journal of ICT Research and Applications, vol. 5, no. 1, pp. 57–71, 2011.

TCHVIALEVA et al., L. "**Skin Roughness Assessment,**" in New Developments in Biomedical Engineering, pp. 341-355. 2010.

THROJAHN et al., C. "**Relation between skin micro-topography, roughness, and skin age,**" Skin Research and Technology, vol. 21, no. 1, pp. 69–75, Feb. 2015.

TRONIER et al., H. "**Surface Evaluation of Living Skin,**" in Advances in Experimental Medicine and Biology, vol. 455, pp. 507–516. 1999.

WALDORF H, et al. **Skin assessment in aesthetic dermatology.** J Drugs Dermatol. Sep-Oct;3(5):621-7. 2004.

WANG, Z., BOVIK, A. C., SHEIKH, H. R., & SIMONCELLI, E. P. **Image quality assessment: from error visibility to structural similarity.** IEEE transactions on image processing, 13(4), 600-612. 2004.

WILCOXON, F. "**Individual comparisons by ranking methods,**" Biometrics pp. 80-83, 1945.

XIE et al., W. **“A Novel Transient Wrinkle Detection Algorithm and Its Application for Expression Synthesis”** IEEE Trans. On Multimedia vol. 19, no. 1, pp. 279-292, Feb. 2017.

YAP, M. H. **“A Survey on Facial Wrinkles Detection and Inpainting: Datasets, Methods and Challenges”** IEEE Trans. On Emerging Topics in Computational Intelligence, vol. 5, no. 1, pp. 505–519, Aug. 2021.

ZHANG, D. and LU, G. **“Review of shape representation and description techniques,”** Pattern Recognition, vol. 37, no. 1, pp. 1–19, Jan. 2004.

ZHANG, Y., CHEN, W., & XIE, X. **A review on deep learning for medical image analysis.** Medical image analysis, 44, 60-78. 2018.

APÊNDICE A – Parecer CEP – Fase 1



UNIVERSIDADE BRASIL



PARECER CONSUBSTANCIADO DO CEP

DADOS DO PROJETO DE PESQUISA

Título da Pesquisa: 2021_11_V3 CLASSIFICAÇÃO GLOGAU DE NÍVEIS DE RUGAS POR IMAGENS ÓTICAS

Pesquisador: Airton Abrahao Martin

Área Temática:

Versão: 2

CAAE: 53699221.9.0000.5494

Instituição Proponente: UNIVERSIDADE BRASIL

Patrocinador Principal: Financiamento Próprio

DADOS DO PARECER

Número do Parecer: 5.223.305

Apresentação do Projeto:

Trata-se de análise de resposta ao parecer pendente nº 5.171.776 emitido pelo CEP em 16/12/2021. Ver campo “Conclusões ou Pendências e Lista de Inadequações” para o parecer desta versão.

Objetivo da Pesquisa:

Trata-se de análise de resposta ao último parecer pendente emitido pelo CEP (referenciado no campo Apresentação do Projeto). Ver campo “Conclusões ou Pendências e Lista de Inadequações” para o parecer desta versão.

Avaliação dos Riscos e Benefícios:

Trata-se de análise de resposta ao último parecer pendente emitido pelo CEP (referenciado no campo Apresentação do Projeto). Ver campo “Conclusões ou Pendências e Lista de Inadequações” para o parecer desta versão.

Comentários e Considerações sobre a Pesquisa:

Trata-se de análise de resposta ao último parecer pendente emitido pelo CEP (referenciado no campo Apresentação do Projeto). Ver campo “Conclusões ou Pendências e Lista de Inadequações” para o parecer desta versão.

Considerações sobre os Termos de apresentação obrigatória:

Trata-se de análise de resposta ao último parecer pendente emitido pelo CEP (referenciado no

Endereço: Rua Carolina Fonseca, 235, térreo, Secretaria Acadêmica, Sala 2

Bairro: ITAQUERA

CEP: 08.230-030

UF: SP

Município: SAO PAULO

Telefone: (11)4858-9224

Fax: (11)2070-0000

E-mail: comite.etica.sp@universidadebrasil.edu.br



UNIVERSIDADE BRASIL



Continuação do Parecer: 5.223.305

campo Apresentação do Projeto). Ver campo “Conclusões ou Pendências e Lista de Inadequações” para o parecer desta versão.

Conclusões ou Pendências e Lista de Inadequações:

TRATA-SE DE ANÁLISE DE RESPOSTA AO PARECER PENDENTE Nº 5.171.776 EMITIDO PELO CEP EM 16/12/2021:

1 - Tanto no PB_INFORMAÇÕES_BÁSICAS_DO_PROJETO quanto no PROJETO_GLOGAU_2021_FINAL aparece na seção "Desenho do estudo" a frase: "Os participantes de pesquisa recrutados farão quatro (3) visitas ao centro de estudo DermoProbes." O que aporta uma inconsistência ao número de visitas ao centro.

RESPOSTA: As informações referentes ao número de visitas ao centro de estudo foram corrigidas como solicitadas. As informações corrigidas são: "Os participantes de pesquisa farão três (3) visitas ao centro de estudo DermoProbes." Estas afirmações podem ser identificadas no projeto no item Design do estudo, pag. 9.

ANÁLISE: Atendida.

Considerações Finais a critério do CEP:

Ressalta-se que cabe ao pesquisador responsável encaminhar os relatórios parciais e final da pesquisa, por meio da Plataforma Brasil, via notificação do tipo “relatório” para que sejam devidamente apreciadas no CEP, conforme Norma Operacional CNS nº 001/13, item XI.2.d.

Este parecer foi elaborado baseado nos documentos abaixo relacionados:

Tipo Documento	Arquivo	Postagem	Autor	Situação
Informações Básicas do Projeto	PB_INFORMAÇÕES_BÁSICAS_DO_PROJETO_1859258.pdf	20/01/2022 17:53:05		Aceito
Outros	CARTA_RESPOSTA_GLOGAU_CEP.pdf	20/01/2022 17:50:44	Airton Abrahao Martin	Aceito
Projeto Detalhado / Brochura Investigador	PROJETO_GLOGAU_2021_CORRIGIDO.pdf	18/01/2022 11:48:02	Airton Abrahao Martin	Aceito
Declaração de Instituição e Infraestrutura	CARTA_DE_ANUENCIA_DermoProbes_GLOGAU.pdf	17/11/2021 19:06:57	Airton Abrahao Martin	Aceito

Endereço: Rua Carolina Fonseca, 235, térreo, Secretaria Acadêmica, Sala 2
Bairro: ITAQUERA **CEP:** 08.230-030
UF: SP **Município:** SAO PAULO
Telefone: (11)4858-9224 **Fax:** (11)2070-0000 **E-mail:** comite.etica.sp@universidadebrasil.edu.br



UNIVERSIDADE BRASIL



Continuação do Parecer: 5.223.305

Outros	CARTA_DE_ANUENCIA_Pesquisador_Principal_GLOGAU.pdf	17/11/2021 19:06:20	Airton Abrahao Martin	Aceito
Folha de Rosto	Folha_de_Rosto_GLOGAU_2021_CEP_ASS.pdf	17/11/2021 19:05:30	Airton Abrahao Martin	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLE_GLOGAU.pdf	14/11/2021 12:48:11	Airton Abrahao Martin	Aceito
Outros	CARTA_DE_ANUENCIA_MEDICO_GLOGAU.jpeg	14/11/2021 12:44:21	Airton Abrahao Martin	Aceito
Declaração do Patrocinador	CARTA_DE_ANUENCIA_EmpresaColaboradora_CHEMYUNION.pdf	14/11/2021 12:43:06	Airton Abrahao Martin	Aceito
Outros	FSE018A21_PT_ORC_21_11_V3.pdf	14/11/2021 12:41:16	Airton Abrahao Martin	Aceito
Outros	FCR048A21_PT_ORC_21_11_V3.pdf	14/11/2021 12:41:03	Airton Abrahao Martin	Aceito
Outros	Curriculo_Lattes_Gustavo.pdf	14/11/2021 12:39:29	Airton Abrahao Martin	Aceito
Outros	Curriculo_Lattes_Lazaro_Pinto_Medeiros_Neto.pdf	14/11/2021 12:38:57	Airton Abrahao Martin	Aceito
Outros	CURRICULO_LATTES_Sidney_Bandeira_Cartaxo.pdf	14/11/2021 12:38:22	Airton Abrahao Martin	Aceito
Outros	Curriculo_Lattes_Airton_Abrahao_Martin.pdf	14/11/2021 12:38:03	Airton Abrahao Martin	Aceito

Situação do Parecer:

Aprovado

Necessita Apreciação da CONEP:

Não

SAO PAULO, 03 de Fevereiro de 2022

Assinado por:

DANIEL SOUZA FERREIRA MAGALHAES
(Coordenador(a))

Endereço: Rua Carolina Fonseca, 235, térreo, Secretaria Acadêmica, Sala 2

Bairro: ITAQUERA

CEP: 08.230-030

UF: SP


Município: SAO PAULO

Telefone: (11)4858-9224

Fax: (11)2070-0000

E-mail: comite.etica.sp@universidadebrasil.edu.br

APÊNDICE B – PARECER CEP – FASE 2



PARECER CONSUBSTANCIADO DO CEP

DADOS DO PROJETO DE PESQUISA

Título da Pesquisa: EN21-0616-01 - AVALIAÇÃO E CLASSIFICAÇÃO DE RUGAS NA PELE EM PARTICIPANTES COM DIFERENTES FOTOTIPOS E AVALIAÇÃO DE ACEITABILIDADE DE UM PRODUTO COSMÉTICO

Pesquisador: SÉRGIO SCHALKA

Área Temática:

Versão: 1

CAAE: 52218121.7.0000.5514

Instituição Proponente: MEDCIN INSTITUTO DA PELE LTDA

Patrocinador Principal: CHEMYUNION LTDA

DADOS DA NOTIFICAÇÃO

Tipo de Notificação: Envio de Relatório Final

Detalhe:

Justificativa: Solicito apreciação do Relatório final.

Data do Envio: 10/10/2022

Situação da Notificação: Parecer Consubstanciado Emitido

DADOS DO PARECER

Número do Parecer: 5.713.173

Apresentação da Notificação:

Relatório final de pesquisa clínica.

Objetivo da Notificação:

Envio de relatório final.

Avaliação dos Riscos e Benefícios:

Não se aplica.

Comentários e Considerações sobre a Notificação:

Foram recrutados 90 participantes para a pesquisa, sendo que 05 participantes (TR14, TR76, TR77, TR88 e TR89) foram considerados perdas de seguimentos pois não retornaram para avaliação final, foram realizadas tentativas de contato, porém sem sucesso.

Endereço: Av. São Francisco de Assis, 218, sala 35, prédio central
Bairro: Cidade Universitária **CEP:** 12.916-900
UF: SP **Município:** BRAGANCA PAULISTA
Telefone: (11)2454-8302 **E-mail:** comiteetica@usf.edu.br



UNIVERSIDADE SÃO
FRANCISCO-SP



Continuação do Parecer: 5.713.173

Desvios de protocolo:

- Estava previsto a inclusão de participantes no grupo I com rugas intensas, porém devido idade solicitada (19-35) os participantes selecionados não apresentaram esta característica.
- O protocolo previa a inclusão de 33 participantes para o grupo I, porém foram inclusos 35.
- Estava previsto a inclusão de participantes no grupo III com rugas menos intensas, porém devido idade solicitada (56-75) os participantes selecionados não apresentaram esta característica.
- O protocolo previa a inclusão de trinta participantes por grupo, porém para o grupo III foi incluído apenas vinte e nove participantes, sem interferência nos resultados apresentados.

Considerações sobre os Termos de apresentação obrigatória:

Adequados.

Conclusões ou Pendências e Lista de Inadequações:

Relatório aprovado.

Considerações Finais a critério do CEP:

APÓS REUNIÃO DO DIA 13/10/2022 O COLEGIADO DELIBEROU PELA APROVAÇÃO DA NOTIFICAÇÃO DO PROJETO DE PESQUISA.

Este parecer foi elaborado baseado nos documentos abaixo relacionados:

Tipo Documento	Arquivo	Postagem	Autor	Situação
Envio de Relatório Final	Rel_final_CEP_EN21_0616_01_v01.pdf	10/10/2022 13:41:16	SÉRGIO SCHALKA	Postado

Situação do Parecer:

Aprovado

Necessita Apreciação da CONEP:

Não

Endereço: Av. São Francisco de Assis, 218, sala 35, prédio central
Bairro: Cidade Universitária **CEP:** 12.916-900
UF: SP **Município:** BRAGANCA PAULISTA
Telefone: (11)2454-8302 **E-mail:** comiteetica@usf.edu.br



UNIVERSIDADE SÃO
FRANCISCO-SP



Continuação do Parecer: 5.713.173

BRAGANCA PAULISTA, 20 de Outubro de 2022

Assinado por:
CARLOS EDUARDO PULZ ARAUJO
(Coordenador(a))

Endereço: Av. São Francisco de Assis, 218, sala 35, prédio central
Bairro: Cidade Universitária **CEP:** 12.916-900
UF: SP **Município:** BRAGANCA PAULISTA
Telefone: (11)2454-8302 **E-mail:** comiteetica@usf.edu.br