

**UNIVERSIDADE NOVE DE JULHO – UNINOVE
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA E GESTÃO DO
CONHECIMENTO**

Aline Cristina Reis da Silva

**Análise do fotótipo cutâneo através de sensoriamento óptico e aprendizado de
máquina**

São Paulo
2023

UNIVERSIDADE NOVE DE JULHO – UNINOVE
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA E GESTÃO DO
CONHECIMENTO

Aline Cristina Reis da Silva

**Análise do fotótipo cutâneo através de sensoriamento óptico e aprendizado de
máquina**

Dissertação apresentada ao Programa de Pós-Graduação em Informática e Gestão do Conhecimento (PPGI) da Universidade Nove de Julho – UNINOVE, como requisito para a obtenção do grau de Mestre em Informática e Gestão do Conhecimento.

Professor Orientador: Dr. Alessandro Melo Deana
Data de ingresso: 03/2021
Linha de pesquisa: Linha 02

São Paulo

2023

Silva, Aline Cristina Reis da.

Análise do fotótipo cutâneo através de sensoriamento óptico e
aprendizado de máquina. / Aline Cristina Reis da Silva. 2023.

67 f.

Dissertação (Mestrado) - Universidade Nove de Julho -
UNINOVE, São Paulo, 2023.

Orientador (a): Prof. Dr. Alessandro M. Deana.

1. Inteligência artificial. 2. Escala Fitzpatrick. 3. Sensor de
reconhecimento de cor. 4. Redes neurais. 5. Fotótipo.

I. Deana, Alessandro M.. II. Título.

CDU 004

ALINE CRISTINA REIS DA SILVA

**Análise do fotótipo cutâneo através de sensoriamento óptico e aprendizado de
máquina**

Dissertação apresentada ao Programa de Pós-Graduação em Informática e Gestão do Conhecimento (PPGI) da Universidade Nove de Julho – UNINOVE, como requisito para a obtenção do grau de Mestre em Informática e Gestão do Conhecimento.

São Paulo, 31 de maio de 2023.

Presidente: Professor Doutor Alessandro M. Deana – Orientador, UNINOVE (PPGI).

Professor Doutor Sidnei A. De Araújo – Membro Interno, UNINOVE (PPGI).

Professor Doutor Renato Araújo Prates – Membro Externo, UNINOVE (PPGI).

Gostaria de expressar minha sincera gratidão a todos os profissionais e professores do Programa de Mestrado em Informática da Universidade Nove de Julho que me apoiaram durante a realização deste trabalho. Gostaria de agradecer ao meu orientador, o Professor Dr. Alessandro Deana, por aceitar me orientar nesta pesquisa, cujo empenho e dedicação foram essenciais para manter minha motivação em alta, especialmente quando enfrente dificuldades ao longo do percurso. Também estendo meus agradecimentos aos amigos e família, pelo apoio na construção da base dos conhecimentos necessários para despertar meu desejo pelo saber, sem essa base este trabalho não seria possível.

AGRADECIMENTOS

A ciência pode ser considerada um registro palimpsestico que se acumula ao longo dos séculos com escritos antigos e modernos. É sobre essa base que a humanidade continua a escrever o futuro, descobrindo novos caminhos, explorando novos territórios e ousando imaginar o impossível. Além disso, a ciência procura ultrapassar os limites da imaginação humana, despertando a curiosidade e encontrando novas formas de pensar e ver o mundo. Expresso meu reconhecimento àqueles que inspiram a ciência ao longo dos anos, dedicando-me com humildade a contribuir modestamente para o progresso do conhecimento humano e prestar homenagem à grandiosidade de suas mentes.

"Na vida, não há nada a temer, apenas a entender."

Marie Curie.

RESUMO

Métodos visuais são frequentemente usados para classificar subjetivamente o tipo de foto de pele humana. No entanto, com os avanços da tecnologia de inteligência artificial, estão surgindo métodos para melhorar os diagnósticos médicos. O uso de inteligência artificial para melhorar o atendimento médico diagnóstico é uma área de pesquisa em rápido crescimento, e este trabalho apresenta uma nova perspectiva para classificar o fotótipo usando um sensor de cor simples e rede neural. A melanina, proteína crítica para a proteção contra a radiação ultravioleta, é o principal determinante na definição do fotótipo da pele. Vários métodos podem classificar a concentração de melanina, como metodologias clínicas, comparações visuais e senso comum regional. No entanto, a Escala de Fitzpatrick é amplamente utilizada e classifica os níveis de concentração de melanina. O objetivo deste estudo é desenvolver uma abordagem de classificador de fotótipos que possa auxiliar diversas áreas médicas, incluindo cosmética, dermatologia, fotobiomodulação e remoção de tatuagens. O processo empregado neste estudo utilizou os dados RGB obtidos da leitura do sensor de cor, sendo enviados para uma rede neural construída no KNIME. Ao analisar os canais de cores RGB, foi revelado que as regiões verde e azul do espectro são fundamentais para a identificação da cor da pele, resultando em uma precisão global de 91% na classificação. A integração do sensor de cor com a inteligência artificial demonstrou ser uma ferramenta, permitindo leituras independentes da iluminação ambiente e insights sobre a saúde do paciente. A pesquisa também superou desafios de recrutamento e demonstrou a relevância dos sensores de cor sobre câmeras tradicionais, ressaltando em possibilidades de aplicações nas áreas médicas, cosméticas e o potencial para enriquecer a prática médica com tecnologias de inteligência artificial.

Palavras-chave: Inteligência Artificial; Escala Fitzpatrick; Sensor de Reconhecimento de Cor; Redes Neurais; Fotótipo.

ABSTRACT

Visual methods are often used to subjectively classify human skin photo type. However, with advances in artificial intelligence technology, methods are emerging to improve medical diagnoses. The use of artificial intelligence to improve diagnostic medical care is a rapidly growing area of research, and this work presents a new perspective for classifying phototype using a simple color sensor and neural network. Melanin, a critical protein for protection against ultraviolet radiation, is the main determinant in defining skin phototype. Several methods can classify melanin concentration, such as clinical methodologies, visual comparisons and regional common sense. However, the Fitzpatrick Scale is widely used and classifies melanin concentration levels. The objective of this study is to develop a phototype classifier approach that can assist several medical areas, including cosmetics, dermatology, photobiomodulation and tattoo removal. The process used in this study used RGB data obtained from the color sensor reading, which was sent to a neural network built in KNIME. By analyzing the RGB color channels, it was revealed that the green and blue regions of the spectrum are key to skin color identification, resulting in an overall classification accuracy of 91%. The integration of the color sensor with artificial intelligence proved to be a tool, allowing independent readings of ambient lighting and insights into the patient's health. The research also overcame recruitment challenges and demonstrated the relevance of color sensors over traditional cameras, highlighting possible applications in the medical and cosmetic areas and the potential to enrich medical practice with artificial intelligence technologies.

Keywords: Artificial Intelligence; Fitzpatrick Scale; Color Recognition Sensor; Neural networks; Phototype

LISTA DE ILUSTRAÇÕES

Figura 1 - Imagem dos azulejos originais	20
Figura 2 - Escala de Von Luschan	20
Figura 3 - Escala de Fitzpatrick.....	21
Figura 4 - Zona de pesquisa.	24
Figura 5 - Absorção da radiação	28
Figura 6 - Representação da pele.....	29
Figura 7 - Rede neural.....	30
Figura 8 - Módulo sensor de cor	32
Figura 9 - Leitura do sensor de cores RGB no gráfico	33
Figura 10 - Demonstração da montagem da placa e sensor.	37
Figura 11 - Leitura em braço real.....	38
Figura 12 - O pipeline de processamento aplicado	39
Figura 13 - Demonstração da leitura feita pelo sensor.....	41
Figura 14 - Rede neural artificial	42
Figura 15 - Demonstração da montagem da rede no KNIME.	43
Figura 16 - Rede neural artificial testando dados originais (O) e gerados (G) por processo de aumento de dados.	48

LSTA DE QUADROS E TABELAS

Quadro 1 – Comparativo entre escalas.....	22
Quadro 2 – Consulta de pesquisa Inteligencia artificial e pele PubMed.....	26
Quadro 3 – Materiais utilizados no experimento.....	38

LISTA DE SIGLAS

AG	Algoritimo Genético
ANN	Neural Artificial
DL	Deep Learning
DNA	Ácido Desoxiribonucleico
DNA	Ácido Desoxirribonucleico
HIS	Hospital Information System
HPP	Hemorragia Pós-Parto
IA	Inteligencia Artificial
IBGE	Instituto Brasileiro De Geografia E Estatística
ISIC	International Skin Image Collaboration
IV	Infravermelho
LCD	Liquid Crystal Display (Tela De Cristal Líquido)
LED	Light-Emitting Diode (Diodo Emissor De Luz)
ML	Machine Learnig
MLP	Multilayer Perceptron
MSE	Erro Médio Quadrático
RFS	Robust Feature Statistics (Atributos Estatísticos Robustos)
RGB	Red, Green E Blue
RNA	Rede Neural Artificial
UV	Radiação Ultravioleta
TC	Tomografia Computorizada
UV	Ultravioleta
UVA	Ultravioleta A
UVB	Ultravioleta B

SUMÁRIO

1. INTRODUÇÃO	13
1.1. Contextualização do tema	13
1.2. Estado da Arte e Identificação de lacunas de pesquisa	16
2. PROBLEMA DE PESQUISA.....	19
2.1. Situação problema.....	19
2.2. Justificativa da pesquisa	22
2.3. Objetivos	23
2.3.1. Objetivo geral.....	23
2.3.2. Objetivos específicos	23
2.4. Delimitação da pesquisa	24
3. PLATAFORMA TEÓRICA.....	25
3.1. Pele	27
3.2. Redes Neurais Artificiais	29
3.3. Sensor de cor	32
3.4. Obtenção de dados	33
4. MÉTODOS E INSTRUMENTOS DE PESQUISA PREVISTOS.....	35
4.1. Ética	35
4.2. Escolha e justificativa da tipologia da pesquisa	35
4.3. Modelo de pesquisa: pesquisa experimental.....	35
4.4. Universo e amostragem.	35
4.5. Instrumentos de pesquisa	36
4.6. Método de coleta	37
4.6.1. Critérios de inclusão e exclusão	39
4.7. Aumento de dados.....	40
4.8. Coleta e tratamento de dados.....	41
4.9. Parametrização da RNA	42
5. ESULTADOS E DISCUSSÕES	45
5.1. Limitações da pesquisa	53
6. TRABALHOS FUTUROS.....	55
7. CONTRIBUIÇÃO PARA A ÁREA	56
8. CONSIDERAÇÕES FINAIS.....	57
REFERÊNCIAS.....	59

1. INTRODUÇÃO

1.1. Contextualização do tema

A inteligência artificial (IA) é uma tecnologia emergente que tem encontrado diversas aplicações no campo da medicina, incluindo a dermatologia (YOUNG et al., 2020). Um dos maiores desafios enfrentados pela dermatologia moderna diz respeito à obtenção, processamento e visualização dos dados corporais relacionados à pele, a fim de permitir a interpretação, diagnóstico e suporte terapêutico. Nesse contexto, a IA pode ser um auxiliar na atenção primária e na pesquisa (SILVA et al., 2019), possibilitando a análise e classificação de características como a tonalidade da cor (DEL BINO et al., 2018).

A pele humana é um órgão que desempenha funções vitais, tais como proteger o corpo contra agentes externos, regular os fluidos corporais, atuar como órgão sensorial vital e controlar a temperatura (VIGLIOLIA, 1991). Outra característica é o pigmento responsável pela proteção contra a radiação solar (PLIKUS et al., 2015). Em resposta à variabilidade intrínseca da pigmentação, ela apresenta uma paleta diversificada de cores, além de servir como um parâmetro importante no diagnóstico e tratamento de doenças de pele (DEL BINO et al., 2018).

A pesquisa dos padrões dessa gama de cores abrange um amplo campo científico, genético, de evolução e cultura. O traço desse fenótipo de diversidade é o mais perceptível e variável entre os humanos e decorre da variabilidade da pigmentação (MOAN et al., 2012).

O gene da melanina, que desempenha um papel biológico fundamental na proteção da pele contra a radiação solar, provavelmente apareceu em nossos ancestrais entre 1,2 e 2 milhões de anos atrás. Esse período corresponde à época em que os hominídeos perderam a pelagem e começaram a depender da melanina, um desenvolvimento que teria tido implicações evolutivas significativas para os primeiros humanos (BARSH, 2003).

A distribuição da melanina na pele varia significativamente entre diferentes regiões geográficas e está altamente correlacionada com a latitude e a intensidade da radiação ultravioleta da região de origem do indivíduo. Essa variação pode ser

explicada por diferenças nas intensidades de UVA (Ultravioleta A) e UVB (Ultravioleta B), bem como por mudanças sazonais ao longo da evolução dos hominídeos (JABLONSKI et al., 2018; DEL BINO et al., 2018). A análise dos padrões de cor da pele e sua evolução oferecem informações valiosas sobre a migração histórica e a distribuição dos primeiros seres humanos em todo o mundo (LIU et al., 2015).

A melanina é dividida em dois tipos: a eumelanina, responsável pela pigmentação marrom, e a feomelanina, que produz o pigmento vermelho ou amarelado (MIOT et al., 2009; JIMBOW et al., 1999). Mudanças na fisiologia do corpo ou exposição a meios externos podem afetar a produção de melanina e resultar em manchas de pigmentação, que podem ser temporárias, como durante a gravidez ou o bronzeamento da pele (COSTIN, 2007).

"Cor da pele" e "tom da pele" são geralmente usados de forma intercambiável para descrever a aparência da pele de uma pessoa. Ambos se referem à variação de cores da pele humana, influenciada por fatores como a quantidade e distribuição de melanina, a presença de hemoglobina, a vascularização e a espessura da pele (ALALUF et al., 2002; STURM, 2009; JABLONSKI et al., 2010; SÁNCHEZ, 2016; JABLONSKI, 2017; BYRD et al., 2018).

Já o termo "fotótipo" se refere a uma classificação mais específica da cor da pele baseada em sua resposta à exposição ao sol. O fotótipo é determinado pela quantidade de melanina na pele e a facilidade com que a pessoa se bronzeia ou queima (MOYAL et al., 2008). A Escala de Fitzpatrick é um sistema abrangente de classificação que categoriza diversos tipos de pele, considerando tonalidade, resposta solar e predisposição ao câncer de pele (FITZPATRICK, 1988). Introduzida por Thomas B. Fitzpatrick, é amplamente usada em dermatologia e pesquisa médica (PANDYA et al., 2000).

A escala divide a população em seis fotótipos, variando de peles claras e sensíveis ao sol a peles escuras e resistentes. Cada fotótipo é definido por atributos como cor natural da pele, reações solares e riscos de câncer de pele.

Além do contexto médico, a Escala de Fitzpatrick também guia tratamentos apropriados, como a escolha de protetores solares conforme a sensibilidade ao sol,

e avalia riscos de exposição excessiva. Assim, a Escala de Fitzpatrick é crucial na compreensão individual da pele, moldando estratégias de cuidado e prevenção, inclusive em relação ao câncer de pele. Estudos como o de KOLLIAS et al. (2005) e GILCHREST (1989) respaldam sua validade na prática clínica e pesquisa.

A metodologia atual de classificação enfrenta desafios inerentes à subjetividade e possíveis erros humanos, pois repousa na comparação visual com uma folha impressa de cores variadas padronizadas (BARSH et al., 2003). Em resposta a essas limitações, emerge a imperativa busca por abordagens mais objetivas e precisas para categorizar tons de pele. Nesse cenário, a inteligência artificial (IA) se posiciona como uma promissora solução para superar esses desafios (SANAL et al., 2019), oferecendo novas perspectivas para aprimorar metodologias diagnósticas (DEL BINO et al., 2018). Recentemente, a literatura dermatológica tem focalizado pesquisas sobre os efeitos dos raios UV na pele, com evidências de que a colorimetria da pele pode prever, com boa aproximação, a resposta cutânea à radiação UV (ANDREASSI et al., 1999).

No passado, os profissionais requeriam exposição a uma ampla variedade de casos clínicos para possuírem vivência para elaborar diagnósticos (BARSKY et al., 2021). Contudo, atualmente a IA pode aproveitar grandes bancos de dados de pacientes como fontes de conhecimento, aproximando a experiência de análise de casos. A IA avançou notavelmente, particularmente na classificação de manchas e padrões em imagens médicas, e a dermatologia é um campo em constante progresso, com potencial para melhorar a precisão e eficiência diagnóstica.

Com os progressos recentes, é provável que sistemas de apoio à decisão e aprendizado de máquina se tornem elementos cotidianos, contribuindo para a compreensão da saúde cutânea e aprimorando abordagens terapêuticas para distúrbios pigmentares. A habilidade da IA de aprender com grandes volumes de dados e extrair complexos padrões na área da saúde (LECUN et al., 2015). Ao desenvolver dispositivos e tecnologias, é crucial considerar cuidadosamente as implicações éticas e realizar implementações criteriosas (YOUNG et al., 2020; UDREA et al., 2020).

Nesse contexto, a utilização da IA e do aprendizado de máquina para analisar dados coletados por sensores de reconhecimento de cor abre oportunidades para identificar parâmetros relevantes, que podem ser então processados por redes neurais para estabelecer correlações com a escala de Fitzpatrick. Esse enfoque viabiliza o desenvolvimento de sistemas diagnósticos para doenças de pele, utilizando os resultados do aprendizado para criar indicadores. A integração sinérgica entre tecnologias de reconhecimento de cor e IA pode ser aplicada em diversas áreas, como a classificação do fotótipo, possibilitando a personalização de produtos e protocolos médicos. Essa convergência pode se tornar uma ferramenta valiosa na análise e interpretação de informações sobre a saúde da pele.

É fundamental ressaltar que uma classificação precisa do tom de pele é crucial para compreender a resposta da pele à radiação UV, garantindo a segurança e eficácia de procedimentos médicos (KAWADA et al., 2000). Neste estudo, apresentamos uma nova perspectiva para a classificação do tom de pele. Nossa abordagem envolve a análise do reflexo RGB capturado por um sensor de cor, combinado com uma rede neural que categoriza os tons conforme a escala de Fitzpatrick.

1.2. Estado da Arte e Identificação de lacunas de pesquisa

Diferentes disciplinas têm incorporado a Inteligência Artificial (IA) em conjunção com o processamento de imagens, e o campo da saúde é um exemplo dessa tendência (WYSTERLÂNYA et al., 2018). Em 2019, uma pesquisa explorou a colaboração entre dermatologistas e IA, demonstrando que essa sinergia resultou em diagnósticos mais precisos do que aqueles realizados exclusivamente por médicos (HEKLER et al., 2019). É imperativo realçar os benefícios econômicos e as potencialidades da IA na área da saúde, gerando conceitos aplicáveis a uma gama diversificada de setores (ADAMSON et al., 2018). No campo da medicina, mais especificamente, as pesquisas dermatológicas se voltam para a compreensão dos fundamentos desse emergente campo, aproveitando os vastos conjuntos de dados médicos e imagens disponíveis para treinamento. Atualmente, diversas investigações concentram-se no diagnóstico e tratamento de doenças dermatológicas (HOGARTY et al., 2020).

Quanto à abordagem de redes neurais artificiais para a análise de imagens médicas relacionadas à pele, destaca-se um conjunto de trabalhos como (ANSARI et al., 2023), (RATH et al., 2023), (CARVALHO, Thiago et al., 2018), (DELAZERI et al., 2021), (FERREIRA et al., 2018), (MAJTNER et al., 2016), (NASR-ESFAHANI et al., 2016), (RATH et al., 2022), (WYSTERLÂNYA et al., 2018) e (YU, L. et al., 2017). Essas pesquisas se concentram na análise de imagens dermatológicas usando redes neurais. A maioria delas busca desenvolver de processamento de imagens digitais para a análise de doenças específicas, com o câncer de pele sendo uma condição frequentemente abordada. No entanto, o uso de módulos de sensor de cor e redes neurais para a classificação automática de tons de pele tem sido pouco explorado, apesar de ter sido previamente estudado para classificar objetos em esteiras, verificar cores de produtos e detecção de superfícies polidas ou não polidas, visando preservar a identidade visual dos produtos. Modelos baseados em módulos de sensor de cor têm demonstrado eficácia tanto, na prática, quanto na academia, mas ainda não receberam ampla atenção como auxiliar na área da saúde.

No contexto da classificação de tons de pele humanos, é comum recorrer a escalas visuais para determinar em qual categoria de Fitzpatrick um indivíduo se enquadra (GUIRRO et al., 2004). No entanto, esse método possui limitações, uma vez que essas escalas não são calibradas e são frequentemente impressas em papel-cartão gráfico para servir como referência. Além disso, a literatura sugere que a resposta do olho humano a variações de contraste é logarítmica (EVANS, 1981), o que amplifica o grau de subjetividade na classificação de tons de pele.

Atualmente, a classificação da cor da pele continua a ser um desafio na área da saúde, visto que poucos dispositivos comerciais estão disponíveis para essa finalidade. Geralmente, tais dispositivos são adquiridos de sites de importação da China, sendo dispendiosos e frequentemente carentes de certificados de calibração para garantir a confiabilidade dos dados e resultados obtidos. Nesse contexto, a literatura ainda carece de pesquisas que demonstrem o uso de módulos de reconhecimento de cor para avaliar a cor da pele humana.

O módulo de reconhecimento de cor proposto oferece um meio de obtenção de informações, gerando dados numéricos nos espectros RGB (vermelho, verde e

azul) por meio de fotodiodos altamente precisos, capazes de detectar nuances em tons de branco. Composta por 64 fotodiodos e 4 LEDs brancos de iluminação, a configuração visa padronizar as leituras e minimizar as interferências da luz ambiente.

Quanto à sua aplicação na saúde, esta é uma fonte de informação a ser explorada. Vale ressaltar que a IA e os sensores não devem ser considerados substitutos, mas sim como complementos para a avaliação clínica e diagnóstico preciso. A IA deve ser entendido como uma aliada para aprimorar a precisão diagnóstica e aperfeiçoar os processos terapêuticos. A capacitação dos dermatologistas no uso da tecnologia é fundamental para garantir a qualidade e a segurança dos diagnósticos e tratamentos baseados em aprendizado de máquina, sensores e redes neurais.

2. PROBLEMA DE PESQUISA

2.1. Situação problema

A revolução tecnológica está transformando a prática médica devido à contribuição das tecnologias, biotecnologia e ao acesso a um vasto conjunto de dados (SANAL et al., 2019). Embora esse processo já esteja presente em outras áreas há muito tempo, tem ganhado um interesse significativo recentemente na área da saúde. Ele está sendo popularizado por empresas que o utilizam em aplicações de aprendizado de máquina e redes neurais para resolver problemas (HOGARTY et al., 2020), tornando a inteligência artificial (IA) um domínio de estudo de grande interesse na área médica. A IA tem o potencial de melhorar o fluxo de trabalho e reduzir erros de interpretação, fornecendo respostas rápidas e precisas dos resultados. Isso resulta em benefícios tanto para os pacientes quanto para os médicos, que agora têm ferramentas para diagnósticos mais precisos, com base na abundância de dados existentes e naqueles gerados pelos pacientes (PAI et al., 2021) (TOPOL, 2019).

Ocorre que as redes neurais buscam refletir o comportamento do cérebro humano e são eficazes de reconhecer padrões e apresentar uma análise profunda e estatística dos dados, trazendo respostas precisas. Uma vez treinadas, permitem a classificação de dados com alta velocidade, relacionando diversos parâmetros de entrada para obter resultados eficientes, como destacado pela IBM (IBM). No campo médico, esses processos têm demonstrado grande potencial (CULLELL-DALMAU et al., 2020), (DEEKS et al., 2020).

Apesar de haver diversidade em pesquisas que abordam o uso de tecnologias computacionais para a detecção de parâmetros clínicos relacionados ao bem-estar e qualidade de vida, no caso da pele, a maioria dessas pesquisas utiliza técnicas de classificação de imagens. Esse processo ocorre por meio da extração de informações para obter o reconhecimento de objetos ou fragmentos desejados em imagens (GONZALEZ et al., 2006).

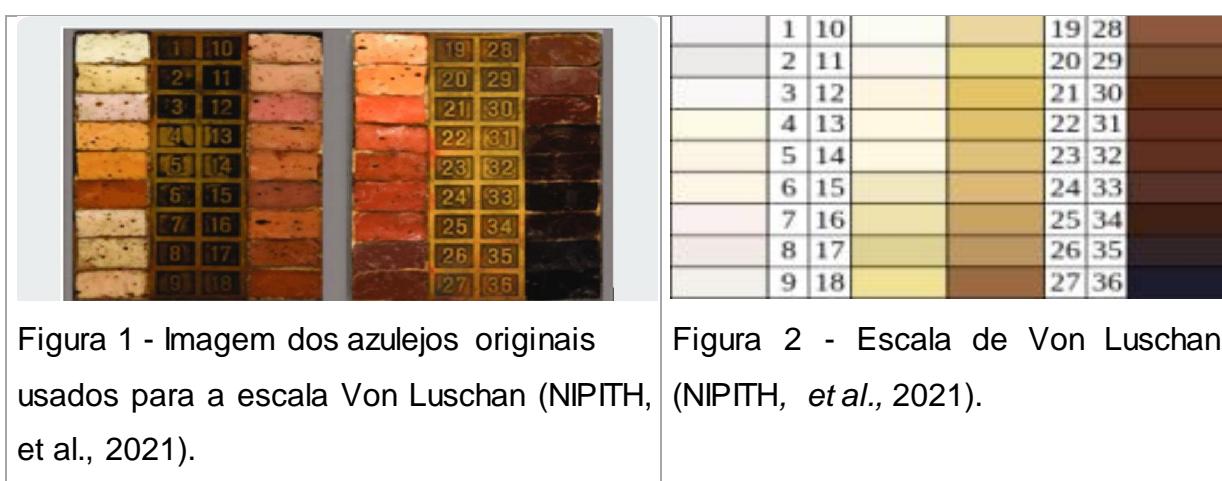
Esse fluxo impulsiona a saúde digital em todo o mundo, não apenas em regiões ricas em recursos, mas também em regiões com recursos limitados (ÖZDEMİR et al., 2018). Existem programas de governo que buscam ampliar a

acesso à saúde de qualidade utilizando de telemedicina para diagnósticos e anamnese remota.

A diversidade em pesquisas que abordam o uso de tecnologias computacionais para a detecção de parâmetros clínicos relacionados ao bem-estar e qualidade vida, no caso da pele, a maioria dessas pesquisas utiliza processos de classificação de imagens, esse usam da extração de informações para obter o reconhecimento de objetos ou fragmentos desejados de imagens (GONZALEZ et al., 2006).

Partindo deste ponto, podem-se encontrar pesquisas que utilizam câmeras e imagens para realizar a classificação e identificação de características visuais da pele, como a sua tonalidade.

A coloração da pele é uma característica adaptativa e mutável que sofreu diversas transformações ao longo da evolução humana (JABLONSK et al., 2000). Nesse contexto, torna-se imprescindível considerar outros elementos, como as variações das tonalidades da pele humana em regiões tropicais, a fim de compreender de forma abrangente os riscos associados à exposição à radiação ultravioleta (MOAN et al., 2012). Existem diversas escalas para a classificação das variações na coloração da epiderme, sendo que se destacam a Escala Cromática de Von Luschan, exemplificada na figura 1 e 2, que categoriza as tonalidades em uma escala de 1 a 36, e a Escala de Fitzpatrick, que classifica as tonalidades de 1 a 6.



A escala cromática de Von Luschan foi criada com a mistura de argilas e corantes, formando azulejo, posteriormente a escala foi atualizada para cores gráficas (figura 3), o método utiliza de 36 parâmetros para agrupar as possibilidades

de tonalidade existentes, essa escala foi bastante usada durante o final do século XIX e início do século XX (SWIATONIOWSKI et al., 2013). Em 1920 passou a ser substituída por métodos que utilizam o reflexo espectrofotométrico, desde 1975 a Escala Fitzpatrick com seis definições de cor e a qual considera o risco de exposição ao sol, à figura 3 apresenta a representação desta escala (BARSH, 2003).

Escala de Fitzpatrick



Figura 3 - Escala de Fitzpatrick

Com objetivo de demonstrar a relação das escalas e melhorar o entendimento, o quadro 1 apresenta os dados reunidos para compilar as escalas usuais e suas respectivas correspondentes em outros parâmetros, além de aspectos da resposta da pele a exposição solar.

Visível	Escala de Fitzpatrick	Escala de Von Lucham	Bronzeamento	Sensibilidade ao sol	Queimadura
Clara	I	1-6	Não se bronzeia	Muito sensível ao sol	Sempre queima
	II	7-13	Bronzeia-se com dificuldade	Sensível ao sol	Queima facilmente
Média	III	14-20	Bronzeia-se	Sensibilidade normal ao sol	Pode queimar inicialmente
	IV	21-26	Bronzeia-se facilmente	Média sensibilidade ao Sol	Dificilmente queima
Escura	V	27-32	Torna-se escura	Pouco sensível ao sol	Habitualmente não se queima
	VI	33-36	Sem grandes alterações	Muito pouco sensível ao sol	Não se queima

Quadro 1 – Comparativo entre escalas

Existem questões visuais passíveis a interpretações subjetivas do avaliador na classificação do fotótipo, é comum a identificação da tonalidade da pele ocorrer por meio de comparações visuais, assim apresenta limitações como a dependência do analisador e a possibilidade de interferência na interpretação devido ao local de análise. Para superar essas limitações, é importante desenvolver formas mais objetivas.

A utilização de um módulo de reconhecimento de cor e IA pode melhorar a compreensão da cor da pele dos indivíduos e a sua correlação com a Escala de Fitzpatrick. A precisão dos resultados obtidos pode contribuir para a escolha de protetor solar, cosméticos, peeling, clareamento, tratamentos a laser, luz pulsada e teledermatologia, podendo ser fundamental para a segurança e eficácia de tratamentos de saúde da pele (GIRRO et al., 2004). Além disso, ampliar a compreensão das respostas fisiológicas da interação da melanina com a luz.

2.2. Justificativa da pesquisa

A aplicação de redes neurais representa uma abordagem eficiente na classificação das cores de pele e no reconhecimento de padrões. Com o uso das redes neurais, conseguimos explorar e extrair características relevantes de forma automatizada e precisa, resultando em uma classificação mais confiável dos diferentes fotótipos cutâneos.

A integração do sistema Arduino, para programação e controle dos dispositivos de aquisição de cores, aliado ao Knine, utilizado para o processamento e análise dos dados, cria uma plataforma de pesquisa de alto desempenho com custo reduzido. Essa abordagem desempenha um papel crucial na prevenção e tratamento de doenças de pele, além de fornecer orientações precisas para condutas médicas e protocolos.

No âmbito acadêmico, a compreensão dos canais RGB tem o potencial de impulsionar pesquisas no campo do reconhecimento de imagens humanas, incluindo a sensoriamento remoto de acúmulo de bilirrubina, que resulta na alteração da cor da pele, conferindo um aspecto amarelado.

Dessa forma, esta proposta almeja disponibilizar informações, com o

propósito de contribuir com o conhecimento na área de classificação de cores de pele. A combinação de redes neurais, sistema Arduino e Knine representa uma promissora abordagem para a análise de imagens da pele e sua aplicação na prática clínica.

2.3. Objetivos

2.3.1. Objetivo geral

Desenvolver uma abordagem de identificação do fotótipo humano através da análise da resposta da pele nos canais RGB, permitindo uma determinação objetiva e em tempo real.

2.3.2. Objetivos específicos

A. Construção de um Banco de Imagens de Pele Humana Validado: O objetivo inicial desta pesquisa é criar um banco de imagens de pele humana que tenham sido devidamente validadas e classificadas conforme a escala de Fitzpatrick. Esse banco de imagens será utilizado como um ponto de referência comparativo para análises subsequentes de dados coletados.

B. Desenvolvimento de uma Abordagem para Classificação de Fotótipo: Uma abordagem será desenvolvida para a classificação precisa do fotótipo com base nos dados de resposta obtidos pelo sensor de cor. Essa abordagem empregará redes neurais como ferramenta para atingir resultados altamente precisos na classificação, visando aprimorar a precisão das análises realizadas.

C. Validação do Método Proposto: A validação do método desenvolvido é um passo crucial desta pesquisa. Serão estabelecidas correlações significativas entre os dados coletados e a Escala de Fitzpatrick, visando demonstrar a eficácia da abordagem proposta na classificação precisa dos diferentes fotótipos.

D. Avaliação da Capacidade Discriminativa da Rede Neural: Outro objetivo é avaliar a capacidade da rede neural em distinguir entre os dados originais e os dados gerados. Isso será feito ao considerar a razão de

geração dos novos dados a partir dos dados coletados inicialmente. Essa avaliação contribuirá para a compreensão da confiabilidade da rede neural na análise e classificação dos dados.

2.4. Delimitação da pesquisa

A figura 4 apresenta a delimitação da pesquisa, que será atuar na intersecção de três áreas: inteligência artificial (I.A.), biologia (fisiologia) e módulo de reconhecimento de cor.

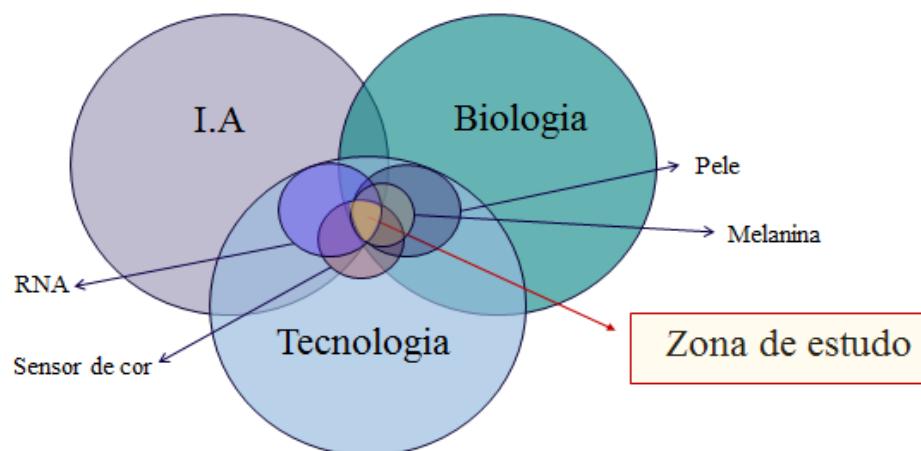


Figura 4 - Zona de pesquisa.

3. PLATAFORMA TEÓRICA

Pretendemos apresentar uma abordagem confiáveis para identificar tons de pele em indivíduos, o que pode ter implicações significativas no desenvolvimento de pesquisas acadêmicas, produtos específicos e no tratamento de questões dermatológicas.

Os principais tópicos a serem desenvolvidos incluem:

- Avaliar da precisão do módulo de reconhecimento de cor na coleta dos canais em RGB;
- Construir o corpo físico de proteção do módulo sensor de cor para garantir resultados mais precisos;
- Desenvolver as linhas de código do sensor de cor e construção da rede neural no KNIME;
- Coletar os dados dos participantes de pesquisa visando diversidade em tons de pele para análise e sua respectiva representação segundo a tabela Fitzpatrick;
- Organizar e analisar os dados coletados;
- Gerar novos dados a partir dos resultados obtidos da análise;
- Submeter todos os dados coletados a análise da rede neural e avaliar a eficácia para a identificação do tipo de pele.
- Conferir se a rede neural consegue distinguir os dados originais dos dados sintéticos.

Durante a busca por artigos e pesquisas que abordam o uso de redes neurais para análise de diagnósticos médicos, observou-se que a maioria dos trabalhos se concentra no processamento de imagens. Por essa razão, existem diversas pesquisas que avaliam fotografias de manchas, tumores e pintas, além de trabalhos que utilizam bancos de imagens de radiografias, ressonâncias magnéticas, ultrassonografias e tomografias. O processo ocorre por meio da análise de uma imagem inicial, que pode ser um exame de imagem, vídeo ou gráfico, sendo submetido a uma rede de aprendizado profundo. Esse dado de entrada é comparado com o banco de aprendizado para apresentar o resultado. A segmentação de imagens também pode ser utilizada em exames gráficos, como a

cardiotocografia, teste ergométrico, eletrocardiograma, eletroencefalograma, eletroneuromiografia e eletrorretinografia. Essas possibilidades de aplicação da inteligência artificial em pesquisas relacionadas à área da saúde são vastas. Embora o uso da classificação de imagens seja amplamente utilizado para a detecção de parâmetros clínicos, quando abordamos pesquisas relacionadas à pele, existem outras abordagens possíveis além da análise por imagens.

No PubMed, por exemplo, foram publicados 2258 artigos que abordam a aplicação de inteligência artificial em parâmetros de pele no período de 2018 a janeiro de 2023. O Quadro 2 apresenta uma compilação dos artigos publicados nos últimos 5 anos com as palavras "inteligência artificial" e "pele".

A análise mostra que o diagnóstico de melanoma maligno (MM) é frequentemente o foco principal da IA para o diagnóstico de doenças de pele (THOMSEN et al., 2021).

Consulta de pesquisa: Inteligência artificial e pele PubMed	
Ano	Quantidade de publicações
Janeiro / 2023	80
2022	624
2021	591
2020	430
2019	322
2018	211

Quadro 2 – Consulta de pesquisa Inteligencia artificial e pele PubMed

Por padrão, as pesquisas visam classificar tons de pele possui em comum o uso de imagens comparativas, processo similar ao apresentado anteriormente. No entanto, essa abordagem apresenta duas grandes questões na avaliação das tonalidades de pele. A primeira delas está relacionada aos parâmetros fotométricos da imagem, que podem levar a uma análise errônea devido à qualidade da luz presente na imagem. A segunda falha diz respeito à necessidade de um hardware poderoso para analisar cada imagem.

O artigo de Rubegni, intitulado "Relationship between minimal phototoxic

dose and skin colour plus sun exposure history: a neural network approach", propõe o desenvolvimento de uma rede neural artificial capaz de prever questões relacionadas à pele a partir de medições de cor combinadas com o fotótipo da pele. Essa pesquisa conclui que não é possível prever com precisão suficiente apenas com base na cor e no fotótipo (RUBEGNI et al., 1998).

A tecnologia representa uma oportunidade para explorar a utilidade dessa ferramenta de diagnóstico e facilitar sua implementação segura e ética nos sistemas de saúde (YOUNG et al., 2020). No entanto, são necessárias mais pesquisas no desenvolvimento de dispositivos automatizados baseados em robótica (ELDER et al., 2021), é necessário conhecimento interdisciplinar para a construção desse tipo de pesquisa.

3.1. Pele

Desde a origem do *Homo sapiens*, a pigmentação da pele que possui a função protetora, juntamente com habilidades de bronzeamento (MOAN et al., 2012), foram vantajosas sob condições da exposição a radiação ultravioleta e são características fundamentais dos humanos modernos (JABLONSKI, 2021). Evidências sugerem que a variação da quantidade de melanina foi moldada por padrões geográficos e mostram uma forte correlação com a latitude e a intensidade da radiação ultravioleta (RUV) da região de origem do indivíduo (JABLONSKI et al., 2010).

A seleção natural influenciou a pigmentação da pele humana, levando a duas linhagens que se adaptaram aos níveis de RUV. A primeira foi gerada por alta RUV perto do equador, importante para as populações que se estabeleceram entre 23 e 46 graus, onde os níveis de UVB (Ultravioleta B) e variaram fortemente conforme a estação, resultando em pigmentação escura, protetora e rica em eumelanina. A outra linhagem foi produzida pela necessidade de fôtons para sustentar a fotossíntese cutânea de vitamina D3 em ambientes com baixo índice de radiação, resultando em pele despigmentada (JABLONSKI et al., 2018).

Os efeitos da radiação ultravioleta (RUV) solar são essenciais para a saúde humana (GALLAGHER et al., 2006). No entanto, ainda há muito a ser descoberto sobre as bases genéticas, evolutivas e culturais que influenciam a cor da pele

humana (MIOT et al., 2007). A cor da pele é uma característica complexa, resultante da interação entre carotenoides, hemoglobina e, principalmente, melanina (JIMBOW et al., 1999).

A evolução humana em áreas tropicais é um fator importante a ser considerado para entender os riscos da radiação ultravioleta (JABLONSKI et al., 2012), (DAVIS et al., 2004). É importante compreender os efeitos da radiação solar sobre o organismo para estabelecer formas de utilizar a inteligência artificial na obtenção de conhecimentos.

A produção da melanina ocorre pelos melanócitos a partir da tirosina, um aminoácido essencial, e existe em duas formas: eumelanina e feomelanina, responsáveis pelos tons marrom e vermelho/amarelado, respectivamente (MIOT et al., 2009). As variações de melanina em cada indivíduo explicam a grande variedade de fenótipos de pele, cabelos e pelos encontrados em humanos (FUCHS, 2007; SLOINSKI et al., 2012). A quantidade de eumelanina presente na pele determina a intensidade do tom marrom, enquanto uma maior concentração de feomelanina resulta em uma pele mais clara.

É importante compreender a estrutura da pele para localizar a produção da melanina, dividida em três camadas: a epiderme, derme e hipoderme ou tecido subcutâneo (HWANG et al., 2014). Na figura 5 é apresentado como os raios RUV são recebidos pela pele.

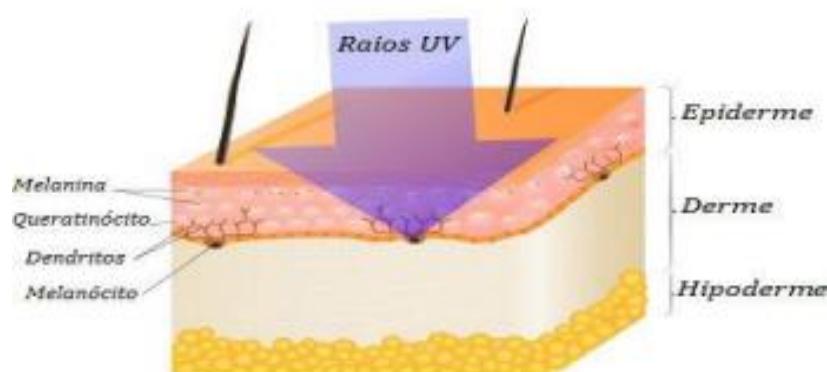


Figura 5 - Absorção da radiação (MUNDO EDUCAÇÃO)

Vale destacar que a melanina não só protege contra a radiação solar

(BARATA, 1994), mas também é um biopolímero com diversas aplicações em áreas como biologia, medicina, química, física e engenharia (PAULIN *et al.*, 2021). Nas últimas décadas, sua utilização tem se expandido para a criação de dispositivos biocompatíveis e biodegradáveis para produtos orgânicos, eletrônica e bioeletrônica.

Como mencionado à exposição aos raios solares ativas à resposta protetora da pele contra danos celulares, resultando na produção de melanina por melanócitos e na deposição dessa melanina nos queratinócitos, visualizado na figura 6 (ORTIZ *et al.*, 2014). Isso forma uma mancha pigmentada contínua que absorve parte da radiação ultravioleta (PLIKUS *et al.*, 2015). Portanto, a melanina protege a pele dos efeitos nocivos da luz solar (WULF *et al.*, 2004) e sua ausência no tecido é uma doença autossômica recessiva causada pela completa ausência ou diminuição da biossíntese de melanina nos melanócitos. Devido à redução, ou ausência de melanina, os albinos são altamente suscetíveis aos efeitos nocivos da radiação ultravioleta e apresentam maior risco de danos e câncer de pele (MARÇON *et al.*, 2019).

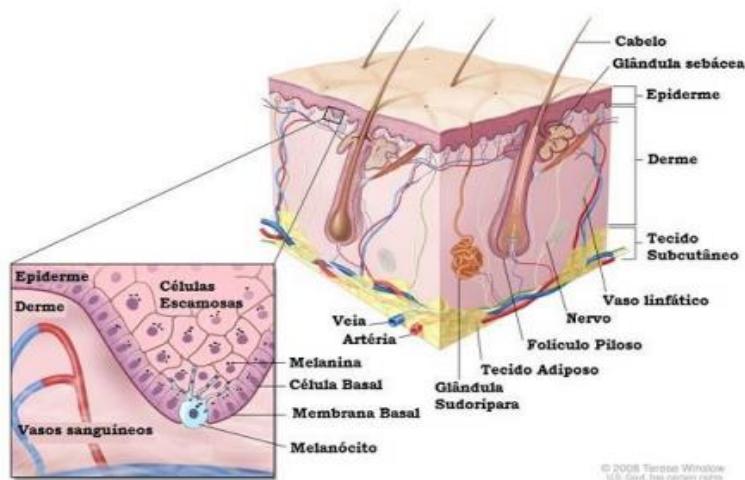


Figura 6 - Representação da pele (WINSLOW, 2008)

Seja de origem solar ou artificial, a radiação solar ultravioleta sempre fez parte do ambiente do homem (GALLAGHER et al., 2020).

3.2. Redes Neurais Artificiais

A Inteligência Artificial (IA) é um campo transdisciplinar que se baseia em diversas áreas do conhecimento, como a engenharia da computação, lógica,

estatística, teoria da decisão e cibernetica e (HOWARD *et al.*, 2019). Em 1943, McCulloch e Pitts desenvolveram o primeiro modelo computacional de um neurônio artificial simplificado, conhecido como RNAs.

Este modelo pode ser representado por modelos matemáticos que processam informações por meio de vários elementos denominados neurônios (SANTOS, 2019). São sistemas de computacionais que simulam o pensamento humano e a função cerebral para resolver problemas.

Como demonstrado na figura 7, os dados de entrada e os pesos correspondentes são definidos inicialmente. O processamento dos dados ocorre na camada oculta onde são trabalhados e, ao fim, apresentados na camada de saída a análise e resultados. Gradualmente, a rede neural aprende com exemplos e incorpora seu conhecimento como uma representação distribuída (RUSSELL *et al.*, 2020).

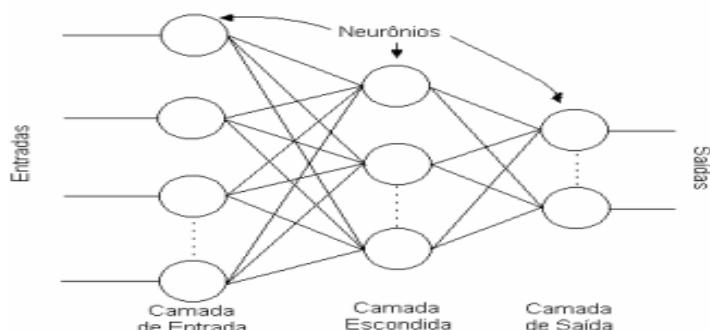


Figura 7 - Rede neural (CARVALHO *et al.*, 2018)

Desde seu início em um pequeno workshop de verão em 1956, os aplicativos de Inteligência Artificial (IA), possibilitados pelo aprendizado de máquina (ML), têm transformado diversos setores, como pesquisas na Internet, comércio eletrônico, tecnologias de sensores, dispositivos robóticos, sistemas de suporte à decisão cognitiva, reconhecimento de imagem e fala.

Antigamente, o treinamento de uma rede neural exigia dias de processamento e recursos computacionais especializados, mas hoje é possível criar redes complexas com recursos disponíveis ao usuário comum (LI *et al.*, 2012), (ZIDAN *et al.*, 2012).

Os modelos de IA estão sendo cada vez mais utilizados na prática clínica, como o processamento de dados, que pode ser usado para analisar imagens médicas (SILVA *et al.*, 2019). Essa prática ganha o nome de informática médica e tem contribuído para a evolução da assistência médica, incorporando a análise de dados para buscar respostas em vários segmentos da saúde (LEHMANN, 2003). Em uma era de avanços médicos e tecnológicos, a utilidade dos modelos de IA continua a crescer (ELDER *et al.*, 2021). No entanto, o processo de coleta de dados no corpo humano apresenta complexidades, tornando desafiador a transformação dos resultados em informações significativas (BARROS *et al.*, 2020), (ELDER *et al.*, 2021).

A integração da tecnologia da computação e ciências médicas tem se consolidado, inicialmente era agilizar em tarefas rotineiras (FELIPE, 2005). Com a evolução, foi possível criar soluções mais complexas de diagnóstico auxiliado por computador, e as doenças de pele, por serem uma especialidade visual, são adequadas para a implementação (WYSTERLÂNYA *et al.*, 2018), (THOMSEN *et al.*, 2021). Por isso, a dermatologia é uma área em que a IA tem obtido destaque, com pesquisas de alta qualidade (ELDER *et al.*, 2021).

Uma das estruturas mais comuns em uso são as redes neurais Multilayer Perceptron (MLP), formadas por camadas de neurônios interconectados em uma rede neural feedforward. A MLP funciona a partir do conceito de aprendizado supervisionado, no qual a rede é alimentada com exemplos de entrada e saída correspondente, permitindo que ela generalize para novos exemplos.

O Multilayer Perceptron é uma rede neural composta de várias camadas de neurônios. Cada camada combina linearmente as entradas ponderadas pelos pesos sinápticos e aplica uma função de ativação não-linear, como a sigmoide, ReLU ou tangente hiperbólica (GOODFELLOW *et al.*, 2016). Essa arquitetura é valorizada por sua habilidade em modelar conexões não lineares e generalizar para novos exemplos, tornando-a uma ferramenta eficaz para solucionar problemas complexos de classificação e regressão.

Algoritmos de retropropagação do erro como o Backpropagation, podem ser empregados para treinar a MLP, permitindo o ajuste dos pesos sinápticos da rede e

minimização do erro entre a saída desejada e a saída real da rede. (ZHANG et al.,2016).

Rumelhart, Hinton e Williams publicaram sobre a MLP e sua variedade de aplicações (RUMELHART et al.,1986), há outros estudos subsequentes, como o de Goodfellow em 2016 (GOODFELLOW et al.,2016), que destacaram a relevância da MLP como uma das principais arquiteturas das redes neurais profundas.

A construção de redes neurais pode ser feita em várias plataformas, como o KNIME, uma plataforma de código aberto que permite a integração de dados, análise e visualização em um único ambiente. O KNIME é uma ferramenta flexível e fácil de usar, que suporta a análise de dados, como aprendizado de máquina, mineração de dados e estatística descritiva. Além disso, sua interface gráfica intuitiva permite que pesquisadores de diferentes áreas possam facilmente manipular e analisar dados sem a necessidade de conhecimentos prévios em programação.

3.3. Sensor de cor

A figura 8 apresenta o módulo de sensor de co, composto por 64 fotodiodos distribuídos em grupos de leitura distintos: 16 com filtros vermelhos, 16 com filtros verdes, 16 com filtros azuis e 16 sem filtro. O módulo é controlado por meio dos pinos S0, S1, S2 e S3, com a saída de informação obtida no pino OUT, e o controle de LED realizado nos pinos LED. Para alimentação, o módulo utiliza os pinos VCC e GND e opera com uma fonte de alimentação de 2,7 a 5,5V, apresentando um erro máximo de 0,2% a 50kHz. O módulo possui dimensões de 31X25X10mm e um peso aproximado de 3g.

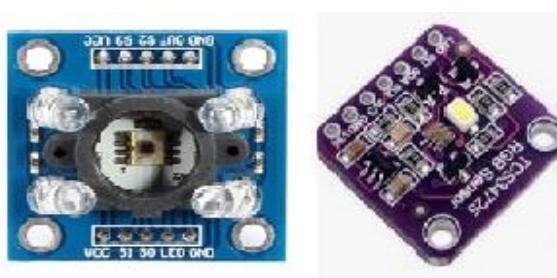


Figura 8 - Módulo sensor de cor

Esse dispositivo é capaz de realizar leituras RGB, filtrar o espectro e fornecer uma saída numérica para a intensidade da cor, sendo o espectro de sensibilidade ilustrado na figura 9.

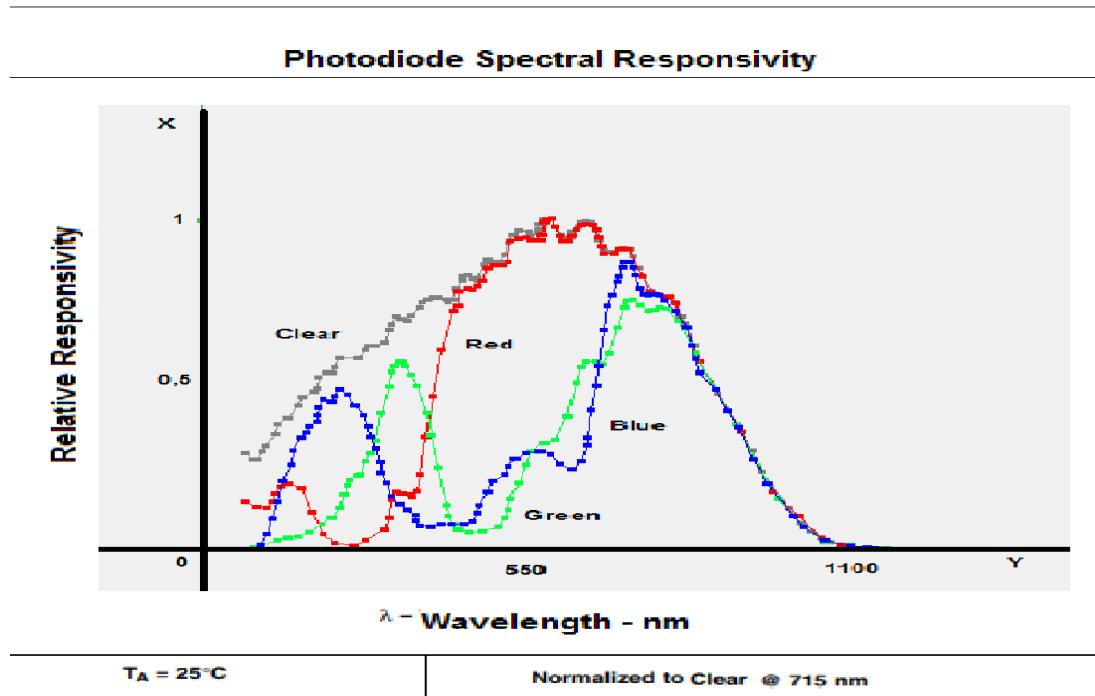


Figura 9 - Leitura do sensor de cores RGB no gráfico

Ademais, o módulo em questão possui um sistema de iluminação próprio que garante que a coleta de dados de reflexão de luz seja sempre reproduzível. Quando integrado a algoritmos de inteligência artificial, esse dispositivo oferece um vasto potencial em diversas áreas, com destaque para a saúde.

Devido à capacidade de detecção de variações de cor, esse sensor é amplamente utilizado na indústria para a identificação de diferenças em embalagens e rótulos. Facilmente pode ser programado por meio de interfaces populares, como o Arduino, Python, C, entre outras, e não requer bibliotecas específicas, como a TAOS099.

3.4. Obtenção de dados

A obtenção de dados tão abrangentes requer investimentos significativos de tempo e recursos, o que pode ser especialmente difícil para pesquisas que envolvem inúmeros participantes. Este desafio é ainda mais acentuado quando se

estuda indivíduos pertencentes a uma população específica, como o Brasil, onde os tons de pele geralmente se situam na faixa de Fitzpatrick II a V, e os fotótipos I e VI são considerados raros. Essas restrições podem representar limitações importantes na viabilidade e no escopo da pesquisa.

Outro fator foi enfrentar os desafios do aumento de dados, utilizamos o aumento de dados que consistiu em adicionar um erro aleatório baseado na dispersão dos dados para cada medição. Essa abordagem ajudou a gerar dados sintéticos que aumentaram o tamanho do conjunto de dados sem comprometer suas propriedades estatísticas.

4. MÉTODOS E INSTRUMENTOS DE PESQUISA PREVISTOS

4.1. Ética

Esta pesquisa foi aprovada pelo Comitê de Ética da Universidade Nove de Julho sob o protocolo número 5.572.533. Todos os participantes concordaram voluntariamente em participar e assinaram o termo de consentimento livre e esclarecido, em conformidade com a Resolução 466/2012 do Conselho Nacional de Saúde do Brasil.

4.2. Escolha e justificativa da tipologia da pesquisa

Propomos apresentar uma avaliação da cromaticidade da pele usando um sensor de cor, sem a necessidade de nenhum hardware especializado (como um cartão de referência de cores) e uma rede neural para triagem seguindo as dimensões da escala de Fitzpatrick.

Como parte do desenvolvimento, foi elaborada uma rede neural para analisar os dados coletados das leituras e identificar os resultados obtidos. O método consiste em comparações e análises individuais de cada canal RGB e as combinações entre os canais para obter entendimento entre as relações das faixas.

O conhecimento resultante contribui para identificar com precisão o fotótipo de pele permitindo que profissionais de saúde elaborem planos de tratamento personalizados que se ajustem às necessidades específicas de cada paciente. Além disso, pode ajudar a identificar indivíduos com maior risco de desenvolver câncer de pele decorrente da exposição solar, possibilitando intervenções e tratamentos precoces.

4.3. Modelo de pesquisa: pesquisa experimental

Este estudo é classificado como uma pesquisa experimental *in vivo*, tendo como objetivo explorar e investigar os fenômenos observados em um ambiente controlado.

4.4. Universo e amostragem.

Tendo como alvo o número de 600 participantes a serem avaliados, os quais

foram recrutados entre os frequentadores da Universidade Nove de Julho, unidade Vergueiro, além de voluntários convidados, com condições de saúde e não inclusos na lista de exclusões. Do objetivo estabelecido foi possível colear dados amostrais de 253 participantes.

Local de pesquisa

Universidade Nove de Julho.

Rua Vergueiro, 235/249 - Liberdade, São Paulo - SP, 01525-000.

4.5. Instrumentos de pesquisa

Nesta pesquisa, utilizamos uma metodologia de coleta de dados que envolveram o preenchimento de fichas, fotos e medição por meio do módulo de reconhecimento de cor. O objetivo foi recrutar 600 participantes, selecionados entre frequentadores da Universidade Nove de Julho (unidade Vergueiro) e voluntários convidados que atendessem aos critérios de saúde. O recrutamento foi realizado apenas após a aprovação do Comitê de Ética. A escolha de 600 participantes teve como objetivo ter 100 amostras por grupo na escala de cor Fitzpatrick.

Para identificar seu fotótipo, os participantes preencheram uma ficha de autodeclaração e o termo de livre consentimento. As respostas foram coletadas em folhas impressas em papel e identificadas por números. Em seguida, o módulo de reconhecimento de cor e a área de contato na parte interna do biceps do participante, foram higienizados com álcool 70%. A pele é avaliada pelo módulo de reconhecimento de cor, e o processo completo levou cerca de 5 minutos, sem causar desconforto ou dor.

O módulo sensor de cor gera valores numéricos para os canais RGB, produzindo uma resposta numérica para cada frequência. Estes resultados são então processados por uma rede neural, estabelecendo conexões entre os valores do módulo, a escala Fitzpatrick e a autodeclaração do fotótipo. O experimento teve como objetivo avaliar a eficácia do módulo de reconhecimento de cor na detecção de informações sobre a tonalidade da pele. O Quadro 3 sumariza os materiais utilizados nas diferentes etapas do experimento, abrangendo desde a compreensão

das respostas do sensor de cor até a construção física do corpo do sensor e os componentes de conexão e alimentação da placa D1.

Materiais utilizados no experimento	
Módulo de reconhecimento de cor	Leitura de luz. R (Vermelho).
	Leitura de luz. G (Verde).
	Leitura de luz. B (Azul).
Materiais utilizados para calibração de parâmetros.	Amostras de matérias que não emitem luz: Tecido, couro, papeis, etc.
	Amostras de materiais que emitem luz: Monitor LCD, lâmpada LED, lâmpadas comuns, etc.
Alimentação do módulo de reconhecimento de cor e placa de processamento.	Bateria de 9V ou Fonte de Alimentação para a Placa. O sensor é alimentado diretamente pela placa e pode ser usado nas conexões de 2,7 a 5,5V.
Processamento.	Placa com conexão Wi-Fi.
Cabos e revestimento.	Materiais para conexões e construção do revestimento do módulo de reconhecimento de cor.
Outros.	Impressões dos termos e questionários.

Quadro 3 – Materiais utilizados no experimento.

4.6. Método de coleta

A montagem ocorre conectando o módulo de reconhecimento de cor a uma placa D1 alimentada por uma bateria de 9V, conforme ilustrado na figura 10.

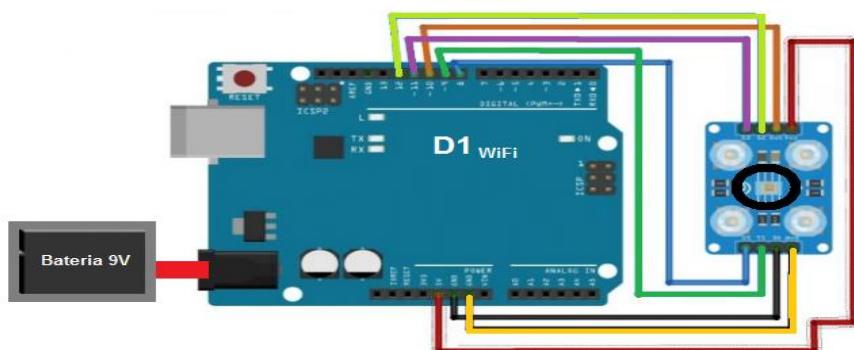


Figura 10 - Demonstração da montagem da placa e sensor.

Ao aproximar o módulo de reconhecimento de cor da superfície são coletadas informações sobre a refletância nas regiões de azul, verde e vermelho, as

quais são apresentadas numericamente no prompt de comando, assegurando leituras precisas e quantitativas. Após o entendimento dos padrões foi possível tabelar os dados, com colunas com as informações RGB, correspondente na Escala Fitzpatrick, somatória de RGB, combinações RG, RB, e GB. Vale ressaltar que a coleta de dados é realizada de maneira não invasiva, não destrutiva e indolor, tornando o método seguro e confortável para os participantes da pesquisa, como ilustrado na figura 11.



Figura 11 - Leitura em braço real.

A escolha da região interna do bíceps para a coleta de dados foi baseada em sua menor propensão a causar desconforto e em sua característica de ser uma área geralmente protegida da exposição solar, o que possibilita uma avaliação mais acurada da tonalidade da pele dos participantes da pesquisa. Para validar os resultados obtidos, foi fotografada a mesma região (sem identificação do participante) e solicitou-se que o participante prenchesse uma autodeclaração sobre a cor da sua pele. Tanto a fotografia quanto a autodeclaração são informações que formam coletadas inicialmente com fonte para gerar mais conhecimento sobre a tonalidade não sendo o foco principal dos dados a serem trabalhados pela rede neural, porém com potencial de uso futuro.

Após essa fase, desenvolvemos a organização de todos os dados coletados para serem submetidos a uma rede neural elaborada no KNIME, assim, foi possível classificar as tonalidades e gerar novas partindo da análise probabilística adquirida da compreensão da relação de cada canal RGB, esses novos dados gerados foram trabalhos pela rede, a finalidade é saber a eficiência e compreender se a rede pode

identificar quais são os dados originais gerados artificialmente. Todo o processo pode ser visualizado no pipeline mostrado na figura 12.

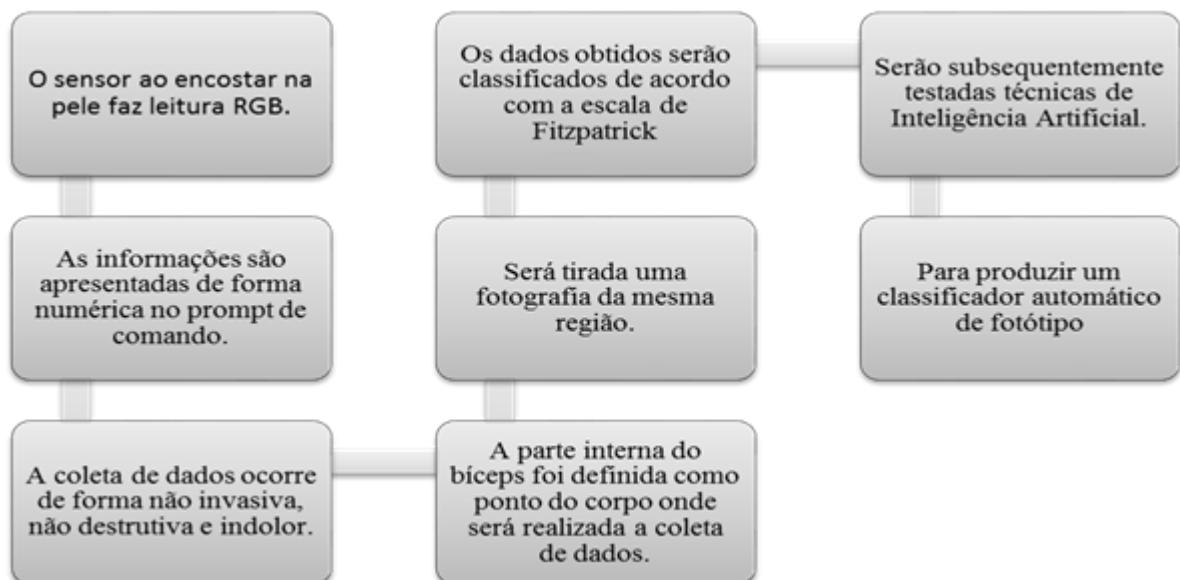


Figura 12 - O pipeline de processamento aplicado

4.6.1. Critérios de inclusão e exclusão

Para assegurar a precisão e a confiabilidade dos resultados da nossa pesquisa, estabelecemos critérios de inclusão e exclusão que estão alinhados com os objetivos definidos.

Critérios de Inclusão:

- Participantes adultos, com 18 anos de idade ou mais.
- Qualquer identidade de gênero.
- Disposição para completar a pesquisa.
- Diversidade de fotótipos de pele.
- Concordância em assinar o termo de consentimento livre e esclarecido.

Critérios de Exclusão:

- Indivíduos com condições crônicas ou agudas que possam limitar sua participação na pesquisa foram excluídos.
- Participantes com condições clínicas agudas que impossibilitam a avaliação da área corporal em estudo foram excluídos.
- A recusa em aceitar os termos de autorização de imagem e consentimento informado também resultou em exclusão.
- Participantess com feridas, úlceras ou outras alterações dermatológicas nos antebraços foram excluídos.
- Aqueles que se submeteram a bronzeamento artificial nos últimos 30 dias foram excluídos.
- Mulheres grávidas foram excluídas.
- Indivíduos sem autonomia para tomar decisões foram excluídos.
- Participantess que passaram por tratamentos psiquiátricos nos últimos 12 meses que pudessem afetar sua percepção ou capacidade de tomada de decisões foram excluídos.
- Participantess em tratamento com medicamentos ou metais pesados que pudessem causar hiperpigmentação, incluindo amiodarona, medicamentos antimaláricos, antibióticos, fenotiazinas, medicamentos de quimioterapia, alguns antidepressivos tricíclicos, medicamentos que afetam os níveis de bilirrubina no organismo e outros medicamentos que pudessem alterar a pigmentação da pele também foram excluídos.

4.7. Aumento de dados

Após a categorização dos dados coletados, foi aplicada o aumento de dados para superar o desafio de ter um conjunto de dados insuficiente. Para aumentar o tamanho do conjunto de dados, utilizamos a análise dos canais RGB e suas combinações para estabelecer razões matemáticas entre esses canais. Dessa forma, foi possível prever a resposta ao apresentar o canal R como entrada. O processo foi realizado em planilhas usando o Excel, adicionando um erro aleatório

baseado na dispersão dos dados para cada medição. Essa abordagem ajudou a gerar dados sintéticos RGB sem comprometer suas propriedades estatísticas, permitindo ampliar o conjunto de dados de treinamento para a inteligência artificial.

4.8. Coleta e tratamento de dados

Nesta seção, explicaremos como os dados RGB são coletados pelo módulo de reconhecimento de cores e lidos na interface de comando, conforme ilustrado na Figura 13. Cada canal é lido individualmente e os dados obtidos são equalizados para se enquadrar nos parâmetros de 0 a 255, sendo a mesma medida utilizada em softwares gráficos. Com esse processo, cada canal pode variar dentro dessa faixa e sua combinação numérica resulta em uma codificação para a cor da pele.

Vermelho :132	Verde :148	Azul :162
Vermelho :135	Verde :145	Azul :153
Vermelho :134	Verde :147	Azul :154
Vermelho :124	Verde :133	Azul :145
Vermelho :115	Verde :128	Azul :132
Vermelho :148	Verde :162	Azul :171
Vermelho :159	Verde :165	Azul :173
Vermelho :214	Verde :219	Azul :223
Vermelho :148	Verde :175	Azul :179

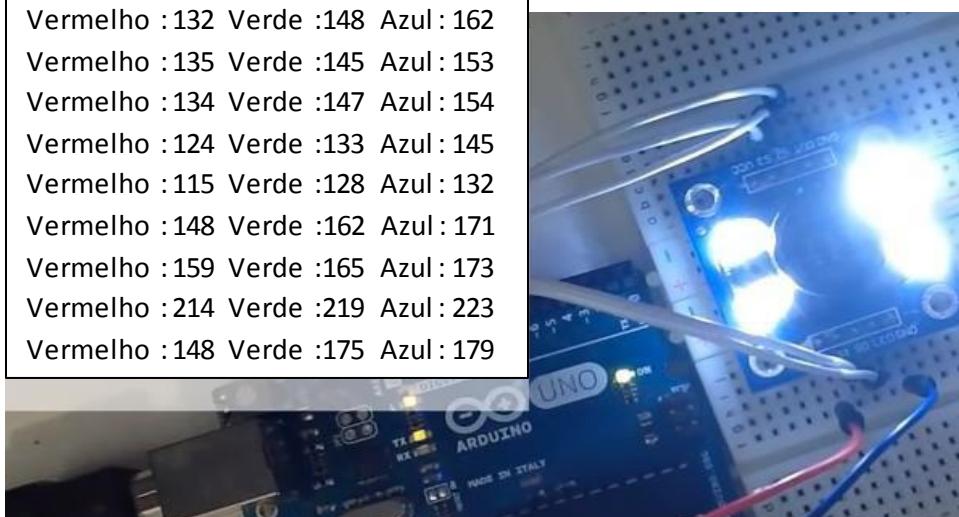


Figura 13 - Demonstração da leitura feita pelo sensor.

Em seguida, os dados foram categorizados e submetidos ao aumento de dados descrito anteriormente no trecho 4.7 desta pesquisa. Todos os dados foram trabalhados em planilhas para entender as relações entre os aspectos RGB ao aproximar o sensor da pele e compreender se há uma proporção que resulte em novas combinações que representem tons reais de pele. Em seguida, essas novas combinações foram devidamente relacionadas à escala de Fitzpatrick, para que cada novo dado tivesse sua representação correspondente na escala.

Essa combinação de dados sintéticos e originais foi submetida à rede neural. Outro ponto observado foi a comparação entre a autodeclaração do participante e a

definição proposta pelo avaliador. Em casos específicos, ambos não concordaram, e esse fator foi trabalhado de forma superficial nesta pesquisa. No entanto, é importante dedicar mais atenção a essa questão em futuras pesquisas.

4.9. Parametrização da RNA

A figura 14 apresenta a parametrização da rede neural utilizada neste processo. O modelo é composto por três camadas ocultas, cada uma contendo nove neurônios. Os dados brutos coletados pelo módulo de sensor de cor são recebidos pela camada de entrada. Em seguida, as camadas ocultas extraem características relevantes e identificam padrões nos dados para, então, transmitir as informações processadas para a camada de saída. É nesta última camada que a rede neural gera uma previsão da cor da pele de cada participante, com base nas informações obtidas e processadas pelas camadas anteriores.

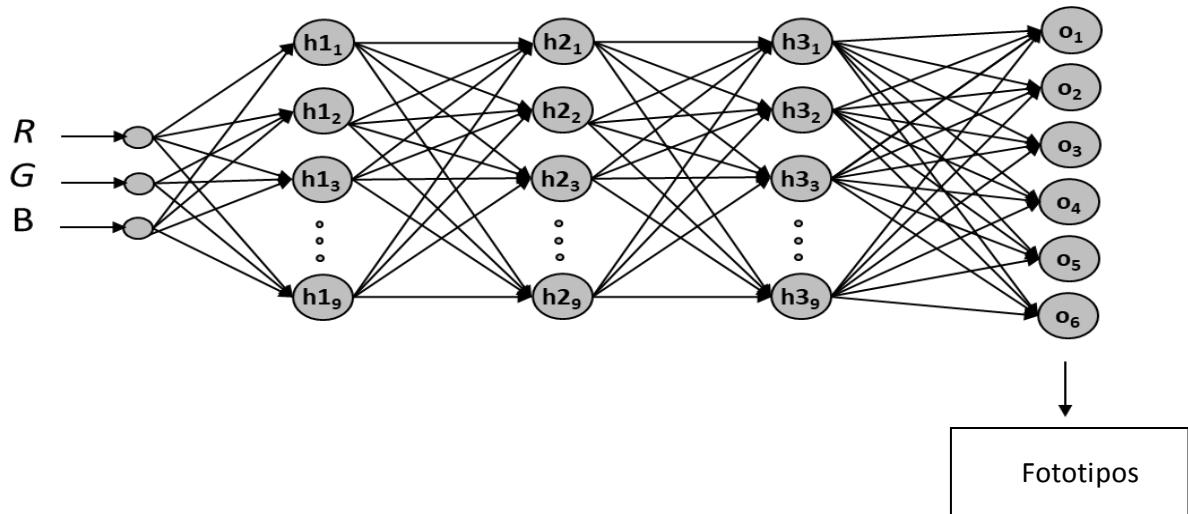


Figura 14 - Rede neural artificial

Para treinar a rede neural, utilizamos um conjunto de exemplos emparelhados com suas respostas corretas, inserindo-os na rede. Durante o treinamento, a rede neural foi capaz de identificar padrões nos dados e gerar previsões precisas sobre a cor da pele de cada participante com base nas informações coletadas pelo módulo de sensor de cor. A arquitetura da rede neural foi adaptada de acordo com o experimento realizado, incluindo o número de neurônios na camada de entrada, que variou de um a três, dependendo do número de sinais a serem analisados. A Figura 15 ilustra o pipeline do treinamento e teste da RNA, o qual foi montado em KNIME

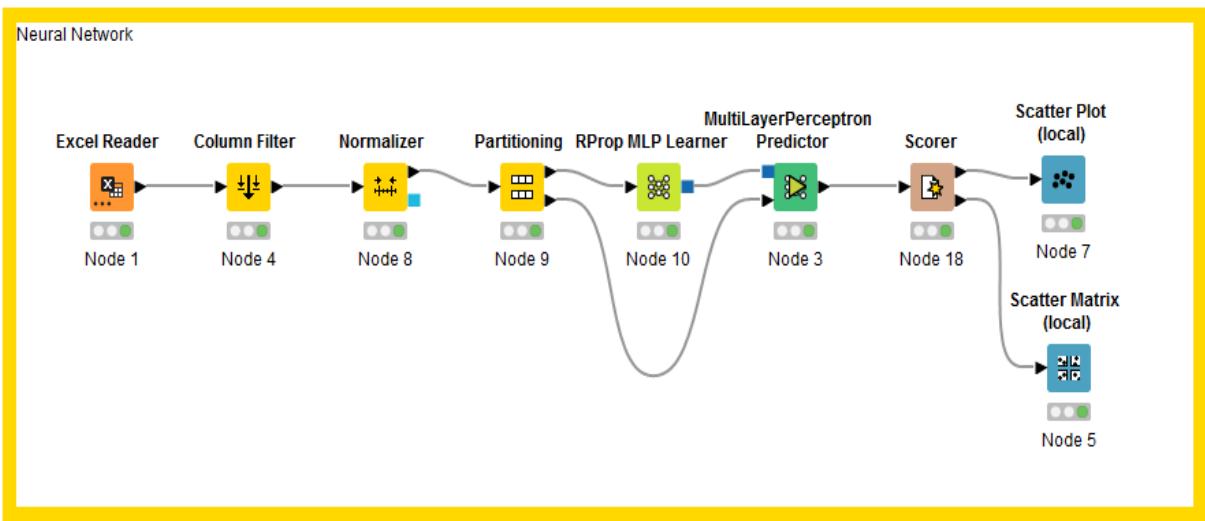


Figura 15 - Demonstração da montagem da rede no KNIME.

O processo começa com a camada de entrada, que recebe os dados brutos gerados pelo módulo sensor de cor RGB. Esses dados são carregados de um arquivo Excel pelo comando Excel Reader, responsável por ler e preparar os dados para serem processados por outros componentes ou etapas do processo de aprendizado de máquina. Em seguida, os dados são encaminhados para a função Column Filter, que seleciona um conjunto específico de colunas dos dados de entrada. Isso é útil quando se deseja trabalhar apenas com algumas variáveis de entrada específicas.

Para garantir que todos os dados estejam na mesma escala, os valores de entrada passam pelo Normalizer, um componente que dimensiona os valores dos dados para estarem na mesma escala, antes de serem encaminhados para às três camadas ocultas, cada uma com nove neurônios. As camadas ocultas são responsáveis por extrair características relevantes e identificar padrões nos dados recebidos pela camada de entrada.

A função de ativação utilizada nesta rede neural é a sigmoide. O Rprop ajustou os pesos da rede neural para minimizar o erro entre as saídas da rede e as respostas corretas para cada exemplo de treinamento. A otimização ajusta as taxas de aprendizado individualmente para cada peso da rede, ajudando a evitar problemas de convergência.

O MLP, que é etapa de pré-processamento de dados que permite que os dados sejam distribuídos e processados em paralelo em um ambiente de computação distribuída. Isso acelera o processo de treinamento de modelos de aprendizado de máquina. A taxa de aprendizagem inicial foi definida como 0,1, e o algoritmo de treinamento Rprop ajusta automaticamente a taxa de aprendizagem, garantindo que o modelo treinado forneça resultados precisos e confiáveis.

O limiar de erro é um parâmetro crucial que indica a margem de erro tolerável em suas previsões. Para esta rede neural, o limiar de erro foi estabelecido em 0,01. Quando o erro médio quadrático (MSE) atinge esse limiar, o processo de treinamento é interrompido. Além disso, um número máximo de iterações foi definido para determinar quantas vezes a rede neural será treinada. Nesse caso, o limite de iterações foi estabelecido em 1000. Quando esse número é alcançado, o treinamento é interrompido.

A etapa final do processo de treinamento de um modelo de aprendizado de máquina é a avaliação de seu desempenho no conjunto de dados de teste, utilizando métricas como precisão, recall e F1-score. Essas métricas são fundamentais para avaliar a capacidade do modelo de generalização para novos dados e identificar possíveis áreas de melhoria. Ajustar a arquitetura da rede neural e os parâmetros de treinamento com base nessas informações pode garantir um desempenho ideal do modelo.

A ferramenta KNIME foi escolhida nesta pesquisa por sua interface gráfica intuitiva, que permitiu analisar dados complexos sem a necessidade de conhecimentos prévios em programação. A eficiência e flexibilidade do KNIME em integrar diversas técnicas de análise de dados em um único ambiente de trabalho justificam sua escolha. A utilização desta ferramenta foi fundamental para a realização de uma análise aprofundada dos dados coletados, contribuindo significativamente para a compreensão dos resultados e para a conclusão desta pesquisa de mestrado.

5. ESULTADOS E DISCUSSÕES

A exploração do fotótipo emerge como um tema de significativa relevância no meio acadêmico, particularmente no âmbito da biofotônica, que se concentra na aplicação direta da luz em tecidos biológicos para obtenção de respostas quantitativas. No contexto da diversidade da população brasileira, recentes dados do IBGE (2021) indicam que 42,7% da população se autodeclararam como brancos, 46,8% como pardos, 9,4% como negros e 1,1% como amarelos ou indígenas. Dentro desta categorização proposta pelo IBGE, emerge uma significativa variação, uma vez que diferentes tonalidades de pele branca, parda e negra são identificadas. Contudo, é importante ressaltar que no Brasil as extremidades da escala de Fitzpatrick são menos comuns, sendo predominantes variações de graus 2 a 5, delineando, assim, um perfil representativo da população. A diversidade histórica que caracteriza a sociedade brasileira confere complexidade à autopercepção, dada à influência de fatores contextuais, culturais e sociais. Ademais, a forma como o indivíduo é percebido por outros e a própria identificação pessoal desempenha um papel subjetivo na definição do fotótipo. Acrescenta-se a isso a notável variabilidade da tonalidade da pele no corpo, onde regiões mais expostas ao sol podem adquirir um tom mais escuro, devido a fatores como bronzeamento, uso de medicações ou influências hormonais.

No âmbito deste estudo, procuramos compreender como os participantes da pesquisa identificam seus próprios fotótipos. Para isso, realizamos uma análise comparativa entre as percepções dos participantes e as avaliações feitas por observadores especializados. Os resultados dessa análise são apresentados de forma detalhada na Tabela 1, fornecendo um panorama das discrepâncias e convergências entre as autopercepções e as avaliações externas.

Avaliador	Autopercepção					
	I	II	III	IV	V	VI
I	15%	0%	0%	0%	0%	0%
II	0%	31%	3%	0%	0%	0%
III	0%	0%	13%	1%	0%	0%
IV	0%	0%	0%	12%	2%	0%
V	0%	0%	0%	0%	7%	9%
VI	0%	0%	0%	0%	1%	5%

Tabela 1 – Matriz de correlação da autopercepção do fotótipo em comparação à classificação do avaliador

A tabela em questão oferece uma análise comparativa entre a autopercepção dos participantes e a avaliação realizada por avaliadores durante a coleta de dados (dois avaliadores). Esses resultados são essenciais para uma compreensão mais profunda de como as pessoas interpretam a tonalidade da própria pele. A análise resultou em um coeficiente Kappa de $0,7889 \pm 0,0325$, demonstrando uma concordância substancial entre os avaliadores. Tal resultado sugere que a autopercepção do fotótipo de cor da pele pode ser avaliada de maneira confiável por meio dos métodos empregados neste estudo. É oportuno observar, porém, que algumas variações na autopercepção podem ocorrer. Vale mencionar que a generalização deste estudo para populações de origens raciais ou étnicas distintas deve ser tratada com cautela, uma vez que a percepção pode diferir entre esses grupos. Além disso, é importante reconhecer que a autopercepção frequentemente está sujeita a imprecisões e subjetividades.

A combinação dos canais de cores RGB permite a criação de uma vasta variedade de tons de pele. Contudo, essa relação pode variar conforme condições de iluminação, e a influência do componente de cor pode não ser uniforme ou linear em todas as situações. Considerando que as tonalidades estão intrinsecamente relacionadas à quantidade de melanina, pesquisas prévias buscaram desenvolver maneiras de mensurar a melanina com base na cor da pele. Embora a tonalidade possa fornecer um indicativo geral da quantidade de melanina presente, é relevante ressaltar que a medição precisa da melanina envolve técnicas mais rigorosas, como a espectrofotometria e biópsias, superando a mera observação visual.

Diversos dispositivos inteligentes e métricas não invasivas, como o uso de câmeras de celular, escalas e cartões, visam oferecer soluções práticas para a identificação da tonalidade da pele. Essas ferramentas não substituem exames laboratoriais para confirmações diagnósticas, especialmente em casos críticos como diagnóstico final de câncer. No entanto, elas têm relevância em protocolos clínicos, permitindo até mesmo a antecipação de condutas médicas e, sobretudo, aplicando-se no campo estético.

Essas considerações sublinham a importância das abordagens baseadas em inteligência artificial para a classificação das tonalidades da pele. Investigações

recentes exploram a utilização de imagens capturadas por câmeras de smartphones para coletar dados RGB e, posteriormente, aplicar classificadores (LIN et al., 2007).

É relevante notar que câmeras de smartphones apresentam variações em seu hardware e distribuição espectral de tela não uniforme, além de sensores de imagem com perfis distintos de sensibilidade espectral (JIANG et al., 2013). A iluminação do ambiente também desempenha um papel relevante, introduzindo "ruídos" nos resultados. Atualmente, não existe um consenso claro sobre como superar questões ambientais, indicando que a cromaticidade da imagem capturada é afetada pela iluminação no local onde a foto foi tirada (WEMYSS et al., 2023). Uma solução recente proposta na literatura é o aplicativo NeoSCB, que utiliza a tela do celular em modo totalmente branco e com brilho máximo para equilibrar a luz durante a captura da foto. Posteriormente, a tela é desligada, criando um diferencial correspondente ao fator ambiente (OUTLAW et al., 2016). Essa abordagem resulta em um diferencial que reflete o ambiente em que a foto foi tirada.

Assim, uma solução comum para minimizar a interferência do ambiente nas leituras dos canais RGB inclui considerar a variação da iluminação ambiente ou controlar a iluminação local, normalmente introduzindo a luz branca (COLLINGS et al., 2016). Os objetivos da abordagem de subtração de ambiente são minimizar a necessidade de equipamentos, como cartões coloridos para calibração. Por esta razão, muitos trabalhos escolhem locais no corpo com facilidade de leitura ou que a cor não seja o principal fator a ser analisado e sim o formato, como é o caso de pesquisas de classificação de manchas cancerosas ou não. Diferentemente dos trabalhos encontrados na literatura, uma das principais características deste trabalho foi o uso do sensor de cor para obter uma leitura RGB com menor interferência da iluminação ambiente, proporcionando uma leitura mais simples e precisa. O sensor possui fotodiodos dedicados a equalizar os canais, portanto, apresenta um resultado controlado e independente do ambiente.

Uma vez superados, a próxima questão são as limitações da rede neural, a necessidade de um grande volume de dados para o treinamento correto do algoritmo. Outro ponto é a dificuldade inerente ao recrutamento de participantes para a pesquisa e a raridade de certos fotótipos, para contornar essa limitação, foi aplicado o aumento de dados para ampliar o conjunto de treinamento. O processo

de aumento envolveu a adição de erros aleatórios com base na dispersão dos dados, a fim de criar dados sintéticos e aumentar o tamanho do conjunto sem alterar suas propriedades estatísticas. A figura 16 apresenta a Rede Neural Artificial (RNA) utilizada para avaliar a semelhança dos dados aumentados em relação aos dados originais, garantindo que os dados aumentados são compatíveis e similares aos dados originais. Esse processo ocorreu em cada elemento do conjunto de dados.

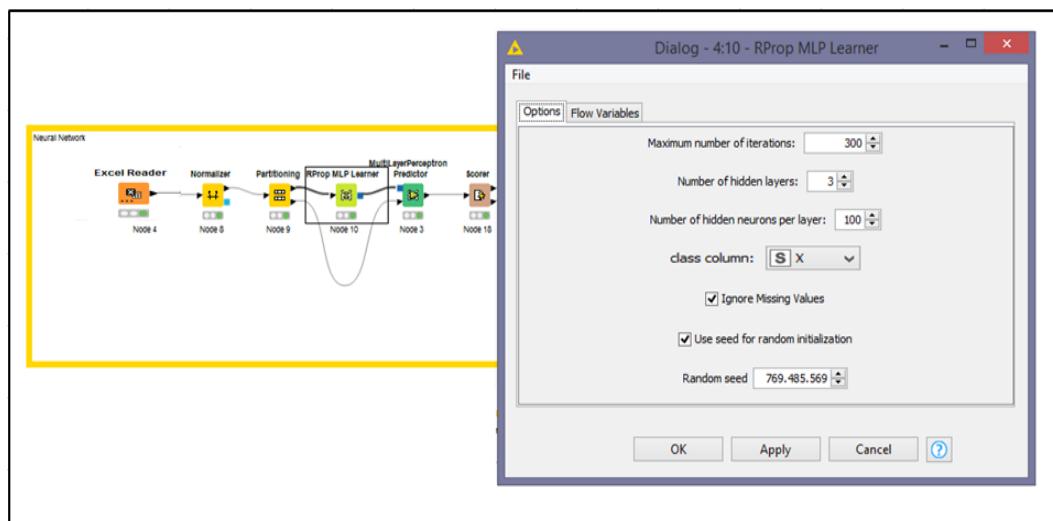


Figura 16 - Rede neural artificial testando dados originais (O) e gerados (G) por processo de aumento de dados.

A Tabela 2 mostra a comparação entre os dados sintéticos e os originais.

Fitzpatrick Sintético Original Precisão Sensibilidade Especificidade Acurácia

VI	Sintético	17%	33%	33%	33%	33%	33%
	Original	33%	17%				
V	Sintético	14%	14%	25%	50%	40%	43%
	Original	43%	29%				
IV	Sintético	38%	38%	75%	50%	50%	50%
	Original	13%	13%				
III	Sintético	22%	33%	40%	40%	25%	33%
	Original	33%	11%				
II	Sintético	31%	31%	67%	50%	60%	54%
	Original	15%	23%				
I	Sintético	31%	15%	57%	67%	57%	62%
	Original	23%	31%				

Tabela 2 – Análise sintética dos dados

O desempenho abaixo do esperado exibido por cada Rede Neural Artificial (RNA) sugere que elas não conseguiram devidamente distinguir entre os dados sintéticos e os dados originais, resultando em uma precisão reduzida. No entanto, essa constatação também implica que a integração dos dados sintéticos ocorreu de maneira bem-sucedida, sem causar alterações significativas nas propriedades estatísticas do conjunto de dados original. Esse resultado é promissor para a pesquisa, pois viabiliza a utilização de um conjunto de dados expandido sem a necessidade de uma coleta extensiva de novos dados.

Com o intuito de avaliar a precisão na classificação da cor da pele conforme a escala de Fitzpatrick, o conjunto de dados ampliado foi introduzido como entrada em uma nova RNA. Identificou-se a região espectral contendo informações de maior relevância para a classificação, e a RNA foi treinada com diversas entradas, englobando canais individuais de cores (R, G, B), combinações de canais (RG, RB, GB) e a abordagem unificada de RGB. Ao avaliar o desempenho da RNA em cada configuração de entrada, buscamos discernir quais canais de cores são mais informativos para uma classificação precisa da tonalidade da pele. A visualização das matrizes de confusão de todas as RNAs treinadas é apresentada nas Tabelas 3 a 9.

Fitzpatrick	R						Precisao	Sensibilidade	Especificidade	Acurácia
	VI	V	IV	III	II	I				
VI	16%	1%	0%	0%	0%	0%	94%	75%	94%	
V	5%	7%	4%	0%	0%	0%	45%	73%	45%	
IV	0%	2%	10%	5%	0%	0%	60%	67%	60%	
III	0%	0%	1%	14%	2%	0%	83%	67%	83%	
II	0%	0%	0%	2%	12%	3%	69%	70%	69%	
I	0%	0%	0%	0%	3%	14%	84%	82%	84%	67%

Tabela 3 - Matriz de confusão do somente do canal vermelho – R

Fitzpatrick	G						Precisao	Sensibilidade	Especificidade	Acuracia
	VI	V	IV	III	II	I				
VI	15%	1%	0%	0%	0%	0%	92%	85%	92%	
V	3%	13%	1%	0%	0%	0%	77%	84%	77%	
IV	0%	1%	15%	1%	0%	0%	91%	85%	91%	
III	0%	0%	2%	14%	2%	0%	82%	90%	82%	
II	0%	0%	0%	1%	15%	1%	89%	84%	89%	
I	0%	0%	0%	0%	1%	15%	93%	95%	93%	85%

Tabela 4 - Matriz de confusão do somente do canal verde – G

B

Fitzpatrick	VI	V	IV	III	II	I	Precisão	Sensibilidade	Especificidade	Acurácia
VI	13%	3%	1%	0%	0%	0%	78%	68%	78%	
V	6%	8%	2%	0%	0%	0%	50%	62%	50%	
IV	0%	2%	14%	1%	0%	0%	83%	69%	83%	
III	0%	0%	3%	11%	2%	0%	67%	80%	67%	
II	0%	0%	0%	2%	14%	1%	81%	81%	81%	
I	0%	0%	0%	0%	1%	16%	95%	93%	95%	71%

Tabela 5 - Matriz de confusão do somente do canal azul – B

RG

Fitzpatrick	VI	V	IV	III	II	I	Precisão	Sensibilidade	Especificidade	Acurácia
VI	16%	0%	0%	0%	0%	0%	97%	83%	97%	
V	3%	12%	1%	0%	0%	0%	72%	90%	72%	
IV	0%	1%	15%	1%	0%	0%	91%	88%	91%	
III	0%	0%	1%	15%	1%	0%	93%	92%	93%	
II	0%	0%	0%	1%	15%	1%	90%	94%	90%	
I	0%	0%	0%	0%	0%	16%	97%	95%	97%	88%

Tabela 6 - Matriz de confusão dos canais RG

RB

Fitzpatrick	VI	V	IV	III	II	I	Precisão	Sensibilidade	Especificidade	Acurácia
VI	16%	1%	0%	0%	0%	0%	93%	79%	93%	
V	4%	11%	1%	0%	0%	0%	68%	81%	68%	
IV	0%	2%	14%	1%	0%	0%	85%	82%	85%	
III	0%	0%	2%	14%	1%	0%	85%	89%	85%	
II	0%	0%	0%	1%	15%	1%	90%	95%	90%	
I	0%	0%	0%	0%	0%	16%	98%	95%	98%	84%

Tabela 7 - Matriz de confusão dos canais RB

GB

Fitzpatrick	VI	V	IV	III	II	I	Precisão	Sensibilidade	Especificidade	Acurácia
VI	16%	0%	0%	0%	0%	0%	98%	85%	98%	
V	3%	13%	1%	0%	0%	0%	79%	91%	79%	
IV	0%	1%	15%	0%	0%	0%	92%	92%	92%	
III	0%	0%	1%	15%	1%	0%	93%	92%	93%	
II	0%	0%	0%	1%	15%	1%	92%	90%	92%	
I	0%	0%	0%	0%	1%	16%	93%	97%	93%	89%

Tabela 8 - Matriz de confusão dos canais GB

Fitzpatrick	RGB						Precisão	Sensibilidade	Especificidade	Acurácia
	VI	V	IV	III	II	I				
VI	16%	1%	0%	0%	0%	0%	96%	87%	96%	
V	2%	14%	1%	0%	0%	0%	82%	88%	82%	
IV	0%	1%	15%	1%	0%	0%	90%	94%	90%	
III	0%	0%	0%	16%	0%	0%	96%	94%	96%	
II	0%	0%	0%	0%	15%	1%	92%	98%	92%	
I	0%	0%	0%	0%	0%	17%	99%	95%	99%	91%

Tabela 9 - Matriz de confusão de todos os canais RGB

Os dados brutos em RGB obtidos das medições realizadas com o sensor de cores, combinados com os gerados matematicamente, foram incluídos na rede neural do KNIME. A configuração utilizada foi de 300 iterações e 3 camadas ocultas, a precisão da rede apresentou um resultado de 91%. A relação entre as camadas e sua acurácia neste estudo resultou que o aumento do número de camadas ocultas torna a solução mais complexa, consumindo tempo de processamento. Porém, sem aumento significativo na acurácia total da rede. A análise individual de cada canal de cor RGB revelou que a reflexão na região verde do espectro contém mais informações sobre a cor da pele, atingindo uma taxa de precisão de 85%. O canal azul seguiu de perto com uma taxa de precisão de 71%. Embora haja alguma sobreposição no espectro de sensibilidade de ambos os canais, a precisão da rede neural artificial (RNA) melhorou em 4% quando combinados. Além disso, ao incluir o canal vermelho, a precisão geral aumentou em 2%.

Ao avaliar os resultados das combinações RGB, identificou-se que as regiões da luz azul e verde são as principais para identificação da cor da pele. O fato pode estar relacionado à teoria das cores complementares, que afirma que cores opostas na roda de cores (como azul e laranja) complementam e se destacam quando próximas. Embora o canal R possa influenciar a cor da pele, não está necessariamente relacionado à presença de melanina, mas pode estar mais relacionado à presença de hemoglobina, vermelhidão decorrente da exposição solar, proporção da espessura da pele, volume de vasos sanguíneos na região, além de outros fatores. A pele mais avermelhada não representa que terá uma proporção maior do componente vermelho, já que é uma mistura de verde e vermelho. Isso significa que, como a pele contém hemoglobina, que é um pigmento que absorve luz verde, ela tende a refletir mais luz vermelha, o que pode aumentar a quantidade de

R na leitura da cor da pele. Vale destacar a alteração decorrente do acúmulo da bilirrubina na pele, que altera a cor adicionando uma tonalidade amarela ou amarronzada, interferindo na classificação.

A medição portátil da bilirrubina cutânea acontece com o aparelho que emitem espectros de luz verde e outro azul. A leitura deste concentrado ocorre por meio de uma processo que mede a volta da emissão dessas faixas de luz para determinar a concentração de bilirrubina. O fato é que a pele, por estar impregnada com a cor amarela, ao receber a luz azul, transforma-a em verde, enquanto a luz verde não sofre alteração. Fazendo um comparativo entre o valor de volta do azul e do verde, é possível determinar a quantidade de bilirrubina. Esse processo é comumente utilizado na neonatologia, pois a medição de bilirrubina em adultos pode sofrer interferências da densidade óssea, o que não ocorre em recém-nascidos (VAN ERK *et al.*, 2019).

Essas interferências não ocorrem em leituras realizadas com o sensor de cor, pois possui mecanismos para apresentar resultados conforme em RGB e sem interferência da iluminação ambiental, podendo ser estudado como uma solução para uma leitura de baixo custo de definição de bilirrubina em bebês e adultos.

Em 2023, uma pesquisa realizou um teste de validação de uma ferramenta de triagem baseada em smartphone para icterícia neonatal em uma população neonatal multiétnica. Os resultados sugerem que em população multiétnica, a correlação é moderada e a concordância baixa, de 67%, devido à diversidade de tonalidades. Sugerindo realizar novas pesquisas que incluam uma população maior e uma gama ampla de valores antes que a ferramenta possa ser considerada para uso na triagem de icterícia em recém-nascidos (NGEOW *et al.*, 2023).

Por esta razão, o sensor de cor apresenta ser mais adequado do que as câmeras para realizar a classificação da pele. Ele é projetado especificamente para medir a intensidade e a distribuição de cor em uma determinada área, enquanto o outro foi projetado para captar imagens. Além disso, os sensores de cor são capazes de detectar cores sutis que podem ser difíceis de ver por uma câmera convencional. Os sensores de cor também podem ser colocados diretamente na pele para obter leituras mais precisas, enquanto as câmeras precisam ser

posicionadas a uma certa distância da pele para obter uma imagem. Por fim, o uso de sensores de cor com inteligência artificial permite uma análise precisa dos dados coletados, tornando-os uma ferramenta para a classificação da pele em várias aplicações médicas e cosméticas.

A análise minuciosa de cada canal de cor RGB pode oferecer informações valiosas sobre aspectos, contribuindo para um melhor entendimento das questões físicas do organismo. A leitura e interpretação dos resultados obtidos pelos sensores podem fornecer insights importantes sobre a saúde do paciente. Integrar tecnologias de inteligência artificial com a assistência clínica tem o potencial de enriquecer a educação, o aprendizado e a prática médica, expandindo os espaços de cura e aprimorando a relação entre médico e paciente de maneiras inovadoras.

5.1. Limitações da pesquisa

A presente investigação apresenta algumas limitações importantes que devem ser consideradas ao interpretar seus resultados. A primeira limitação está relacionada à disponibilidade de dados para tons de pele raros. Para contornar essa limitação, foi utilizado o algoritmo de aumento de dados, sendo eficaz na minimizar o impacto do tamanho da amostra. No entanto, a extrapolação dos resultados para outros países com fenótipos distintos deve ser feita com cautela.

Com relação à subjetividade na classificação da pele, observou-se que diferentes profissionais podem classificar o mesmo caso de maneiras diferentes o que pode afetar a confiabilidade dos resultados obtidos. Isso indica que os resultados obtidos podem não refletir adequadamente a resposta. Portanto, é necessário considerar protocolos padronizados para a classificação da pele, bem como o treinamento de profissionais para minimizar essa subjetividade. Além disso, o uso de tecnologias como o aprendizado de máquina pode contribuir para aprimorar a precisão e a confiabilidade da classificação da pele. (FELIPE, 2005).

Outro ponto é determinar a rede neural com desempenho adequado, a quantidade de camadas requerida e os recursos computacionais apropriados também são fatores críticos que podem influenciar a precisão dos resultados.

Já as limitações decorrentes da natureza da investigação estão relacionadas à dificuldade de garantir a uniformidade de tonalidade na pele dos participantes, uma vez que sofrem alterações de tom por diversos fatores. Em suma, é importante considerar essas limitações ao interpretar os resultados desta pesquisa e buscar soluções para minimizar seu impacto em futuros estudos. A utilização de soluções tecnológicas e estatísticas, bem como a uniformização do processo, pode ser considerada para reduzir o impacto dessas limitações e melhorar a precisão dos resultados.

6. TRABALHOS FUTUROS

Existem diversas possibilidades de aplicação de redes neurais e módulo de sensores de cor com o intuito de melhorar soluções tecnológicas que buscam realizar testes não invasivos na área da saúde. Uma abordagem promissora é a utilização da combinação de redes neurais e outros sensores associados ao módulo sensor de cor na medicina, visando obter a classificação de diversos indicadores clínicos, como bilirrubina, detecção de doenças de pele, avaliação de marcas de nascença, sintomas de hipotermia, hemoglobina e monitoramento de sinais vitais.

Uma importante direção para trabalhos futuros é o aprimoramento dos algoritmos e desenvolver um aplicativo móvel que possibilite a coleta de dados e o emprego remoto na telemedicina. A expansão do conjunto de dados se torna premente com o propósito de garantir resultados mais confiáveis na classificação de indicadores clínicos. A expansão do conjunto de dados se torna premente com o propósito de garantir resultados mais confiáveis na classificação de indicadores clínicos. A avaliação da eficácia em diferentes cenários e o estabelecimento de diretrizes para sua aplicação emergem como passos cruciais com vistas a assegurar a precisão e segurança desses sistemas.

7. CONTRIBUIÇÃO PARA A ÁREA

O âmago desta pesquisa reside na exploração da sinergia entre um sensor de cor e a inteligência artificial, visando classificar o fotótipo de acordo com a escala de Fitzpatrick, alicerçada na análise da refletância do tecido na faixa visível da luz (RGB).

Tal abordagem carrega consigo uma série de contribuições substanciais para o campo da saúde e da tecnologia, proporcionando insights cruciais sobre a interação entre as tonalidades de pele e contribuindo para a estipulação de padrões na interpretação desses dados por meio de redes neurais. A metodologia proposta pela pesquisa tem o potencial de influenciar variadas esferas médicas, permitindo a adaptação dos parâmetros radiométricos para terapias de luz. Além disso, essa pesquisa oferece vastas oportunidades para a integração de tecnologias, servindo como solução tanto em ambientes hospitalares como na prestação de assistência remota em dermatologia, e também nos campos da cosmética e da remoção de tatuagens.

Em síntese, a utilização do sensor de cor viabiliza a formulação de novas abordagens de leitura de padrões por meio da pele, de forma instantânea e não invasiva, sem a necessidade de coletar amostras biológicas para análise laboratorial. Essa inovação tem o potencial de otimizar consideravelmente a eficácia e precisão dos protocolos de tratamento, ao mesmo tempo que incere a ciencias da computação e informática em ambientes hospitalares e de atendimento médico.

8. CONSIDERAÇÕES FINAIS

O estudo apresentado possui implicações de relevância tanto no âmbito da biofotônica quanto na engenharia clínica. A utilização módulo sensor de cor com redes neurais sugere a capacidade de promover diagnósticos mais ágeis e precisos relacionados às condições que influenciam a coloração da pele. A integração de disciplinas diversas também se destaca como um fator enriquecedor, capaz de aprimorar a assistência clínica e conceber soluções inovadoras e eficazes em prol dos pacientes.

O experimento empregou redes neurais para classificar os dados resultantes do módulo sensor de cor, de acordo com a Escala de Fitzpatrick. Ainda que dispositivos inteligentes e métricas não invasivas possam contribuir para identificar o fotótipo, é relevante destacar que as soluções envolvendo câmeras de smartphones manifestam variações em resposta às condições de iluminação, afetando a precisão das medições. Em contrapartida, o sensor de cor se destaca como uma alternativa mais precisa e consistente para aferir a coloração cutânea, uma vez que sua concepção específica objetiva a mensuração da intensidade e distribuição da cor numa área delimitada.

Com base na análise dos resultados obtidos por meio da fusão dos dados brutos em RGB com aqueles gerados matematicamente para a rede neural do KNIME, foi possível inferir que a reflexão na região verde do espectro abrange mais informações sobre a coloração da pele, alcançando uma precisão de classificação de 85%. A reflexão na região azul segue de perto com uma precisão de 71%. Vale mencionar que, embora o canal vermelho possa influenciar a coloração cutânea, não está necessariamente ligado à presença de melanina, mas pode relacionar-se a fatores como a presença de hemoglobina, vermelhidão decorrente da exposição solar, a proporção da espessura da pele, o volume de vasos sanguíneos na área e outros elementos.

Este estudo também ilustra que a ampliação do número de camadas ocultas na rede neural não necessariamente culmina numa melhoria da acurácia da solução, mas acarreta complexidade adicional e maior tempo de processamento.

A abordagem aplicada com o sensor de cor poderá representar, num cenário futuro, uma alternativa acessível para a determinação da bilirrubina tanto em bebês como em adultos, pois fornece resultados em formato RGB sem ser impactada por iluminação ambiental, e igualmente propicia o desenvolvimento de aplicativos integrados aos sensores, viabilizando o uso remoto. Todavia, para validar a aplicabilidade da triagem baseada em smartphones, novas investigações são prementes. Por fim, o estudo corrobora a eficácia da geração de novos dados sintéticos por meio da análise dos espectros RGB, bem como a capacidade de classificação alcançada via rede neural.

Sumarizando, os desfechos desta pesquisa atestam o potencial das medições da coloração da pele empregando sensores de cor, conjugados à IA, para oferecer resultados tangíveis e contribuições para a medicina. Em face de avanços contínuos nesse âmbito, podemos antecipar melhorias substanciais na precisão de diagnósticos médicos e na qualidade global da assistência, repercutindo positivamente na vida das pessoas.

REFERÊNCIAS

1. ADAMSON, A. S.; SMITH, A. Aprendizado de máquina e disparidades de cuidados de saúde em dermatologia. *JAMA Dermatology*, v. 154, 2018.
2. ALALUF, S. et al. The impact of epidermal melanin on objective measurements of human skin colour. *Pigment Cell Res*, v. 15, n. 2, p. 119-26, 2002.
3. ANDREASSI, L.; FLORI, M. L.; RUBEGNI, P. Sun and skin. Role of phototype and skin colour. *Adv Exp Med Biol*, v. 455, p. 469-75, 1999.
4. ANSARI, M. Y. et al. Dense-PSP-UNet: A neural network for fast inference liver ultrasound segmentation. *Comput Biol Med*, v. 153, 2023.
5. BARATA, E. A. F. A cosmetologia: funções e estruturas da pele. 2^a ed. São Paulo: Pharmabooks, 2008.
6. BARROS, W. K. P. et al. Proposal of the CAD System for Melanoma Detection Using Reconfigurable Computing. *Sensors (Basel)*, v. 20, n. 11, 2020.
7. BARSH, G. S. What controls variation in human skin color? *PLoS Biol*, v. 1, n. 1, 2003.
8. BARSKY, A. et al. "Virtual patients versus standardized patients in the training of health professionals in dermatology: a systematic review." *BMC Med Educ*, v. 21, n. 1, 2021.
9. BYRD, K. M.; WILSON, G.; DOVIDIO, J. F. The relationship between race and skin tone: A conceptual and methodological review. *Advances in Group Processes*, v. 35, p. 87-113, 2018.
10. CARVALHO, T. A.; BARROS, A. C. F. Detecção de câncer de pele do tipo melanoma utilizando técnicas de processamento digital de imagem e redes neurais artificiais; 2018.
11. COLLINGS, S. et al. Non-Invasive Detection of Anaemia Using Digital Photographs of the Conjunctiva. *Plos One*, v. 11.

12. COSTIN, G. E.; HEARING, V. J. Human skin pigmentation: melanocytes modulate skin color in response to stress. *FASEB J*, v. 21, n. 4, p. 976-994, 2007.
13. CULLELL-DALMAU, M. et al. Research Techniques Made Simple: [name of technique]. *J Invest Dermatol*, v. 142, n. 2, p. e38-e44, 2022.
14. DAVIS, G. E. Jr.; LOWELL, W. E. Chaotic solar cycles modulate the incidence and severity of mental illness. *Med Hypotheses*, v. 62, n. 2, p. 207-214, 2004.
15. DEEKS, J. J.; DINNES, J.; WILLIAMS, H. C. É provável que a sensibilidade e a especificidade de SkinVision tenham sido superestimadas. *J Eur Acad Dermatol Venereol*, v. 34.
16. DEL BINO, S.; DUVAL, C.; BERNERD, F. Clinical and Biological Characterization of Skin Pigmentation Diversity and Its Consequences on UV Impact. *Int J Mol Sci*, v. 19, n. 9, 2018.
17. DELAZERI, A. V.; STEVANI, E. S. Classificação de câncer de pele usando redes neurais convolucionais: uma análise do desempenho de classificação em um conjunto de dados desbalanceado [Bachelor's thesis]. Universidade Tecnológica Federal do Paraná, 2021.
18. DYTCH, H. E.; WIED, G. L. Artificial neural networks and their use in quantitative pathology. *Anal Quant Cytol Histol*, v. 12, n. 6, p. 379-93, 1990.
19. ELDER, A. et al. The role of artificial intelligence in cosmetic dermatology- Current, upcoming, and future trends. *J Cosmet Dermatol*, v. 20, n. 1, p. 48-52, 2021.
20. EVANS, A. L. *The evaluation of medical images*. Bristol: Hilger, 1981.
21. FELIPE, J. C. Desenvolvimento de métodos para extração, comparação e análise de características intrínsecas de imagens médicas, visando à recuperação perceptual por conteúdo; 2005.
22. FERREIRA, B. E. S. Segmentação semântica de lesões de pele utilizando redes neurais convolucionais; 2018.

23. FITZPATRICK, T. B. The validity and practicality of sun-reactive skin types I through VI. *Arch Dermatol*, v. 124, n. 6, p. 869-871, 1988.
24. FUCHS, E. Scratching the surface of skin development. *Nature*, v. 445, n. 7130, p. 834-842, 2007.
25. GALLAGHER, R. P.; LEE, T. K. Adverse effects of ultraviolet radiation: a brief review. *Progress in Biophysics and Molecular Biology*, v. 92, n. 1, p. 119-131, set. 2006. DOI: 10.1016/j.pbiomolbio.2006.02.011. PMID: 16580054.
26. GILCHREST, B. A. Skin aging and photoaging: an overview. *Journal of the American Academy of Dermatology*, v. 21, n. 3 Pt 2, p. 610-613, 1989. DOI: 10.1016/s0190-9622(89)70126-9.
27. GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. Deep learning. MIT Press, 2016.
28. GUIRRO, E.; GUIRRO, R. Fisioterapia dermatofuncional. 3. ed. São Paulo: Manole, 2004.
29. HEKLER, A. et al. Improved skin cancer classification by combining human and artificial intelligence. *European Journal of Cancer*, v. 120, p. 114-121, 2019.
30. HOGARTY, D. T. et al. Artificial Intelligence in Dermatology-Where We Are and the Way to the Future: A Review. *American Journal of Clinical Dermatology*, v. 21, n. 1, p. 41-47, fev. 2020. DOI: 10.1007/s40257-019-00462-6. PMID: 31278649.
31. HOWARD, J. Artificial intelligence: Implications for the future of work. *American Journal of Industrial Medicine*, v. 62, n. 11, p. 917-926, nov. 2019. DOI: 10.1002/ajim.23037. PMID: 31436850.
32. HWANG, E. et al. Gallic acid regulates skin photoaging in UVB exposed fibroblast and hairless mice. *Phytotherapy Research*, 2014.
33. INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). Características étnico-raciais da população. 2021. Disponível em:

<https://www.ibge.gov.br/estatisticas/sociais/populacao/26767-caracteristicas-etnico-raciais-da-populacao.html>. Acesso em: 23 abr. 2023.

34. JABLONSKI, N. G.; CHAPLIN, G. Human skin pigmentation as an adaptation to UV radiation. *Proceedings of the National Academy of Sciences of the United States of America*, v. 107, Suppl 2, p. 8962-8968, maio 2010. DOI: 10.1073/pnas.0914628107. PMID: 20445093; PMCID: PMC3024016.
35. JABLONSKI, N. G.; CHAPLIN, G. The evolution of human skin coloration. *Journal of Human Evolution*, v. 39, n. 1, p. 57-106, jul. 2000. DOI: 10.1006/jhev.2000.0403. PMID: 10896812.
36. JABLONSKI, N. G. *Skin: A natural history*. University of California Press, 2017.
37. JABLONSKI, N. G.; CHAPLIN, G. The Genetics of Skin Color Variation and Pigmentation Disorders. *Annual Review of Genomics and Human Genetics*, v. 19, p. 1-22, set. 2018. DOI: 10.1146/annurev-genom-083117-021440. PMID: 29925248.
38. JABLONSKI, N. G. The evolution of human skin pigmentation involved the interactions of genetic, environmental, and cultural variables. *Pigment Cell & Melanoma Research*, v. 34, n. 4, p. 707-729, jul. 2021. DOI: 10.1111/pcmr.12976. PMID: 33825328; PMCID: PMC8359960.
39. JIANG, J.; LIU, D.; GU, J.; SUSSTRUNK, S. What is the space of spectral sensitivity functions for digital color cameras? In: *Proceedings of IEEE Workshop on Applications of Computer Vision*, 2013. DOI: 10.1109/WACV.2013.6475015.
40. JIMBOW, K. et al. Biology of Melanocytes. In: FITZPATRICK, T. B. et al. *Dermatology in General Medicine*. v. 1. New York: McGraw-Hill, 1999.
41. KAWADA, Akira. Risk and preventive factors for skin phototype. *Journal of Dermatological Science*, 2000. DOI: 10.1016/S0923-1811(99)00074-2.

42. KOLLIAS, N.; BAQER, A. H.; PHILIPS, N. Skin phototypes: classification, evolution, and response to phototherapy. *Journal of Investigative Dermatology Symposium Proceedings*, v. 10, n. 2, p. 289-291, 2005. DOI: 10.1111/j.1087-0024.2005.10103.x.
43. LE CUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, n. 7553, p. 436-444, maio 2015. DOI: 10.1038/nature14539. PMID: 26017442.
44. LEHMANN, T. M. et al. Content-based Image Retrieval in Medical Applications for Picture Archiving and Communication Systems. *SPIE*, 2003.
45. LI, B. N. et al. A new unified level set method for semiautomatic liver tumor segmentation on contrast-enhanced CT images. *Expert Systems with Applications*, v. 39, n. 10, p. 9661-9668, 2012. DOI: 10.1016/j.eswa.2012.02.063.
46. LIBRANTZ, A. F. et al. Artificial intelligence based system to improve the inspection of plastic mould surfaces. *Journal of Intelligent Manufacturing*, v. 28, p. 181-190, 2017. DOI: <https://doi.org/10.1007/s10845-014-0969-5>.
47. LIN, J.; FISHER, D. Melanocyte biology and skin pigmentation. *Nature*, v. 445, n. 7130, p. 843-850, 2007. DOI: 10.1038/nature05660.
48. LIU, F. et al. Genetics of skin color variation in Europeans: genome-wide association studies with functional follow-up. *Human Genetics*, v. 134, n. 8, p. 823-835, 2015. DOI: 10.1007/s00439-015-1568-y.
49. MAJTNER, T.; YILDIRIM-YAYILGAN, S.; HARDEBERG, J. Y. Combining deep learning and hand-crafted features for skin lesion classification. In: 2016 Sixth International Conference on Image Processing Theory, Tools and Applications (IPTA), 2016, p. 1-6. IEEE.
50. MARÇON, C. R.; MAIA, M. Albinism: epidemiology, genetics, cutaneous characterization, psychosocial factors. *Anais Brasileiros de Dermatologia*, v. 94, n. 5, p. 503-520, 2019. DOI: 10.1016/j.abd.2019.09.023.

51. MIOT, L. D. B. et al. Pesquisa comparativa morfológica de melanócitos em lesões de melasma. Anais Brasileiros de Dermatologia, v. 82, n. 6, p. 529-534, 2007.
52. MIOT, L. D. B. et al. Physiopathology of melasma. Anais Brasileiros de Dermatologia, v. 84, n. 6, p. 623-635, 2009. DOI: 10.1590/S0365-05962009000600008.
53. MOAN, J.; NIELSEN, K. P.; JUZENIENE, A. Immediate pigment darkening: its evolutionary roles may include protection against folate photosensitization. The FASEB Journal, v. 26, n. 3, p. 971-975, 2012. DOI: 10.1096/fj.11-195859. Epub 2011 Dec 9.
54. MOAN, J.; NIELSEN, K. P.; JUZENIENE, A. Immediate pigment darkening: its evolutionary roles may include protection against folate photosensitization. FASEB J, v. 26, n. 3, p. 971-5, 2012. DOI: 10.1096/fj.11-195859. Epub 2011 Dec 9. PMID: 22159146.
55. MOYAL, D.; FOURTANIER, A. Broad-spectrum sunscreens provide better protection from solar ultraviolet-simulated radiation and natural sunlight-induced immunosuppression in human beings. Journal of the American Academy of Dermatology, v. 58, n. 5, p. S149-S154, 2008. DOI: 10.1016/j.jaad.2007.04.039.
56. MUNDO EDUCAÇÃO. Biologia Melanina. Disponível em: <https://mundoeducacao.uol.com.br/biologia/melanina.htm>.
57. NASR-ESFAHANI, E. et al. Melanoma detection by analysis of clinical images using convolutional neural network. In: 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Aug 2016, pp. 1373-1376.
58. NGEOW, A. J. H. et al. Validation of a smartphone-based screening tool (Biliscan) for neonatal jaundice in a multi-ethnic neonatal population. J Paediatr Child Health, Feb 2023; 59(2): 288-297. DOI: 10.1111/jpc.16287. Epub 2022 Nov 28. PMID: 36440650.

- 59.CHAROENNGAM, N.; SRIUSSADAPORN, S. Darker Skin Color Measured by Von Luschan Chromatic Scale and Increased Sunlight Exposure Time Are Independently Associated with Decreased Odds of Vitamin D Deficiency in Thai Ambulatory Patients. *J Nutr Metab*, 2021. DOI: 10.1155/2021/8899931
- 60.NOV, O. et al. The Transformation of Patient-Clinician Relationships With AI-Based Medical Advice: A "Bring Your Own Algorithm" Era in Healthcare. arXiv preprint arXiv:2008.05855, 2020 Aug 13.
- 61.ORTIZ, A. A.; YAN, B. E.; D'ORAZIO, A. J. Ultraviolet radiation, aging and the skin: Prevention of damage by topical camp manipulation; 2014.
- 62.OUTLAW, F. et al. Smartphone screening for neonatal jaundice via ambient-subtracted sclera chromaticity. *PLoS One*, v. 15, n. 3, p. e0216970, 2020. DOI: 10.1371/journal.pone.0216970. PMID: 32119664; PMCID: PMC7051077.
- 63.ÖZDEMİR, V.; HEKİM, N. Birth of Industry 5.0: Making Sense of Big Data with Artificial Intelligence, "The Internet of Things" and Next-Generation Technology Policy. *OMICS*, v. 22, n. 1, p. 65-76, 2018. DOI: 10.1089/omi.2017.0194. Epub 2018 Jan 2. PMID: 29293405.
- 64.PAI, V. V.; PAI, R. B. Artificial intelligence in dermatology and healthcare: An overview. *Indian J Dermatol Venereol Leprol*, v. 87, n. 4, p. 457-467, 2021 [SEASON]. DOI: 10.25259/IJDVL_518_19. PMID: 34114421.
- 65.PANDYA, A. G.; GUEVARA, I. L. Disorders of hyperpigmentation. *Dermatol Clin*, v. 18, n. 1, p. 91-98, 2000. DOI: 10.1016/s0733-8635(05)70138-x.
- 66.PAULIN, J. V.; FORNACIARI, B.; BREGADIOLLI, B. A.; BAPTISTA, M. S.; GRAEFF, C. F. O. Melanina: Um pigmento natural multifuncional; 2021.
- 67.PLIKUS, V. M.; SPYK, V. N. E.; PHAM, K.; GEYFMAN, M.; KUMAR, V.; TAKAHASHI, S. J.; ANDERSEN, B. The circadian clock in skin: Implications for; 2015.
- 68.GONZALEZ, R. C.; WOODS, R. E. Digital Image Processing (3rd Edition). PrenticeHall, Inc., Upper Saddle River, NJ, USA; 2006.

69. RATH, A. et al. A Bibliometric Review: Brain Tumor Magnetic Resonance Imagings Using Different Convolutional Neural Network Architectures. *World Neurosurg*, 2023 Feb;170:e681-e694. DOI: 10.1016/j.wneu.2022.11.091. Epub 2022 Nov 25. PMID: 36442778.
70. RUBEGNI, P. et al. Relationship between minimal phototoxic dose and skin colour plus sun exposure history: a neural network approach. *Photodermatol Photoimmunol Photomed*, v. 14, n. 1, p. 26-30, 1998. DOI: 10.1111/j.1600-0781.1998.tb00005.x. PMID: 9582083.
71. RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. *Nature*, v. 323, n. 6088, p. 533-536, 1986. DOI: 10.1038/323533a0.
72. RUSSELL, S.; NOVIG, P. *Artificial intelligence: A modern approach*. Harlow: Pearson, 2020.
73. SANAL, M. G.; PAUL, K.; KUMAR, S.; GANGULY, N. K. Artificial Intelligence and Deep Learning: The Future of Medicine and Medical Practice. *J Assoc Physicians India*, v. 67, n. 4, p. 71-73, 2019. PMID: 31309802.
74. SÁNCHEZ, E. L. The skin color paradox and the American racial order. *Social Forces*, v. 94, n. 4, p. 1613-1638, 2016. DOI: 10.1093/sf/sow005.
75. SANTOS, A. P. Análise e comparação do desempenho de diferentes arquiteturas de redes neurais artificiais profundas aplicadas triagem de lesões de pele / André Pires dos Santos – São Paulo; 2019.
76. SILVA, A. M. M.; PATROCÍNIO, A. C.; SCHIABEL, H. *Medical Image Processing and Analysis*; 2019.
77. SLOMINSKI, A. T. et al. Sensing the environment: Regulation of local and global homeostasis by the skin's neuroendocrine system; 2012.
78. STURM, R. A. Molecular genetics of human pigmentation diversity. *Human Molecular Genetics*, v. 18, n. R1, p. R9-R17, 2009. DOI: 10.1093/hmg/ddp003.

79. SWIATONIOWSKI, A. K. et al. Technical note: comparing von Luschan skin color tiles and modern spectrophotometry for measuring human skin pigmentation. *Am J Phys Anthropol*, v. 151, n. 2, p. 325-30, 2013. DOI: 10.1002/ajpa.22274. PMID: 23633083.
80. TCS3200, TCS3210 PROGRAMMABLE COLOR LIGHT-TO-FREQUENCY CONVERTER; Disponível em: <https://cdn.awsli.com.br/945/945993/arquivos/TCS3200%20TCS3210.pdf>; TAOS099 – JULY 2009.
81. WULF, C. H. et al. Skin aging and natural photoprotection; 2004.
82. WYSTERLÂNYA K. P. BARROS, D. S. MORAIS, AND M. A. C. FERNANDES. Detecção de Cancer de Pele com Redes Neurais Artificiais; 2018.
83. YOUNG, A. T. et al. Artificial Intelligence in Dermatology: A Primer. *J Invest Dermatol*, v. 140, n. 8, p. 1504-1512, 2020. DOI: 10.1016/j.jid.2020.02.026. Epub 2020 Mar 27. PMID: 32229141.
84. YU, L. et al. Automated melanoma recognition in dermoscopy images via very deep residual networks. *IEEE Transactions on Medical Imaging*, v. 36, n. 4, p. 994–1004, April 2017.
85. ZHANG, L.; LI, S.; LI, J. A Survey on Deep Learning for Big Data. *Information Fusion*, v. 42, p. 146-157, 2018.
86. ZIDAN, A. et al. Level set-based CT liver computer aided diagnosis system. *Int J Imaging Robotics*, v. 9, n. 1, p. 26-36, 2012.