

UNIVERSIDADE DE SÃO PAULO

Instituto de Ciências Matemáticas e de Computação

**Avaliação da segmentação da pele saudável para
classificação de fotótipos cutâneos em imagens
dermatoscópicas**

Gabriel Oliveira Jacó

Monografia - MBA em Inteligência Artificial e Big Data

Gabriel Oliveira Jacó

**Avaliação da segmentação da pele saudável para
classificação de fotótipos cutâneos em imagens
dermatoscópicas**

Monografia apresentada ao Departamento de Ciências de Computação do Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo - ICMC/USP, como parte dos requisitos para obtenção do título de Especialista em Inteligência Artificial e Big Data.

Área de concentração: Inteligência Artificial

Orientadora: Profa. Dra. Maria Cristina Ferreira de Oliveira

Versão original

São Carlos

2025

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi
e Seção Técnica de Informática, ICMC/USP,
com os dados inseridos pelo(a) autor(a)

Oliveira Jacó, Gabriel
048a Avaliação da segmentação da pele saudável para
classificação de fotótipos cutâneos em imagens
dermatoscópicas / Gabriel Oliveira Jacó; orientadora
Maria Cristina Ferreira de Oliveira. -- São Carlos,
2025.
56 p.

Trabalho de conclusão de curso (MBA em
Inteligência Artificial e Big Data) -- Instituto de
Ciências Matemáticas e de Computação, Universidade
de São Paulo, 2025.

1. Inteligência Artificial. 2. Ciências da
Computação. 3. Visão computacional. I. Ferreira de
Oliveira, Maria Cristina, orient. II. Título.

Gabriel Oliveira Jacó

**Evaluation of healthy skin segmentation in skin phototype
classification using dermoscopic images**

Monograph presented to the Departamento de Ciências de Computação do Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo - ICMC/USP, as part of the requirements for obtaining the title of Specialist in Artificial Intelligence and Big Data.

Concentration area: Artificial Intelligence

Advisor: Profa. Dra. Maria Cristina Ferreira de Oliveira

Original version

São Carlos

2025

Folha de aprovação em conformidade
com o padrão definido
pela Unidade.

No presente modelo consta como
folhadeaprovacao.pdf

Este trabalho é dedicado a todos aqueles que buscam diminuir as desigualdades no mundo.

AGRADECIMENTOS

Agradeço, em primeiro lugar, à minha esposa Isabela Penha Martins de Araújo, pelo apoio incondicional, paciência e compreensão em todos os momentos desta jornada. Sua presença constante foi fundamental para que eu tivesse forças e motivação para seguir adiante.

Expresso também minha profunda gratidão à minha orientadora, Profa. Dra. Maria Cristina Ferreira de Oliveira, pela paciência, dedicação e pelas valiosas orientações ao longo de todo o desenvolvimento deste trabalho. Sua confiança e incentivo foram determinantes para a realização desta pesquisa.

Por fim, estendo meus agradecimentos a todos que, direta ou indiretamente, contribuíram para a conclusão deste trabalho.

“O estudo, a busca da verdade e da beleza são domínios em que nos é consentido sermos crianças por toda a vida.”

Albert Einstein

RESUMO

JACÓ, G. **Avaliação da segmentação da pele saudável para classificação de fotótipos cutâneos em imagens dermatoscópicas.** 2025. 56 p. Monografia (MBA em Inteligência Artificial e Big Data) - Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2025.

Este trabalho tem como objetivo investigar a pertinência da segmentação da pele saudável em imagens dermatoscópicas no processo de classificação de fotótipos cutâneos. Para tanto, utilizou-se a métrica Individual Typology Angle (ITA), padronizada no espaço de cor CIELAB, a fim de obter distribuições representativas dos tons de pele. A abordagem comparou dois modelos de classificação Random Forest: um treinado com valores de ITA calculados após a segmentação da pele saudável por meio de uma rede U-Net, e outro utilizando diretamente os dados brutos, sem segmentação. Os resultados mostraram que a segmentação promove apenas um ganho marginal no desempenho, sugerindo que a sua utilização não é imprescindível em contextos similares. Conclui-se que a investigação contribui para a reflexão sobre a robustez metodológica na avaliação de vieses raciais em Inteligência Artificial aplicada à dermatologia, indicando que estratégias mais simples podem ser igualmente eficazes.

Palavras-chave: Viés. Inteligencia Artificial. Dermatologia. ITA. CIELAB. Fitzpatrick. Trabalho de conclusão de curso (TCC).

ABSTRACT

JACÓ, G. **Evaluation of healthy skin segmentation in skin phototype classification using dermoscopic images.** 2025. 56 p. Monograph (MBA in Artificial Intelligence and Big Data) - Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2025.

This work aims to investigate the relevance of healthy skin segmentation in dermoscopic images for skin phototype classification. The study employed the Individual Typology Angle (ITA), standardized in the CIELAB color space, to obtain representative distributions of skin tones. Two Random Forest classification models were compared: one trained with ITA values calculated after segmenting healthy skin using a U-Net network, and another using raw data without segmentation. Results showed that segmentation yields only a marginal performance gain, suggesting that its use is not strictly necessary in similar contexts. It is concluded that this investigation contributes to the methodological discussion on assessing racial bias in Artificial Intelligence applied to dermatology, indicating that simpler strategies may be equally effective.

Keywords: Bias. Artificial Intelligence. Dermatology. ITA. CIELAB. Fitzpatrick. Segmentation.

LISTA DE FIGURAS

Figura 1 – Foto dermatoscópica. ID: ISIC0024344 Fonte: Skin Cancer MNIST: HAM10000 Disponível em https://www.kaggle.com/datasets/kmader/skin-cancer-mnist-ham10000	26
Figura 2 – Foto dermatoscópica. ID: ISIC0024384 Fonte: Skin Cancer MNIST: HAM10000 Disponível em https://www.kaggle.com/datasets/kmader/skin-cancer-mnist-ham10000	27
Figura 3 – Foto dermatoscópica. ID: ISIC0024431 Fonte: Skin Cancer MNIST: HAM10000 Disponível em https://www.kaggle.com/datasets/kmader/skin-cancer-mnist-ham10000	27
Figura 4 – Arquitetura da rede U-Net. Fonte: https://miro.medium.com/v2/resize:fit:1358/1*0qJdnSxkerwZPCWVdLPpHw.png	30
Figura 5 – Cenário 1: pipeline sem segmentação (ITA calculado sobre a imagem completa).	33
Figura 6 – Cenário 2: pipeline com segmentação (ITA calculado em ROI de pele saudável).	34
Figura 7 – Métricas de treino	38
Figura 8 – Precisão e recall	39
Figura 9 – Dice vs Threshold	39
Figura 10 – Máscara de lesão predita	40
Figura 11 – Máscara de lesão predita	40
Figura 12 – Máscara de lesão predita	40
Figura 13 – Matriz de confusão Classificador Controle treinado somente com dados originais	46
Figura 14 – Matriz de confusão do classificador sem ITA com segmentação de pele saudável	46
Figura 15 – Matriz de confusão do classificador com ITA com segmentação de pele saudável	47
Figura 16 – Imagem ID: ISIC 0132369	47
Figura 17 – ISIC 0132369: Distribuição ITA sem segmentação	48
Figura 18 – ISIC 0132369: Distribuição ITA com segmentação	48
Figura 19 – Imagem ID: ISIC 0107306	48
Figura 20 – Imagem ID: ISIC 0107306: Distribuição ITA sem segmentação	49
Figura 21 – Imagem ID: ISIC 0107306: Distribuição ITA com segmentação	49

LISTA DE TABELAS

Tabela 1 – Classificação da Escala de Fitzpatrick	28
Tabela 2 – Classificação da tonalidade da pele com base no ITA (Individual Typology Angle)	29
Tabela 3 – Distribuição percentual dos estratos (diagnóstico + área) no HAM10000 após split em TRAIN, VAL e TEST.	35
Tabela 4 – Distribuição percentual das classes no conjunto completo e nos <i>splits</i> de treinamento, validação e teste.	37
Tabela 5 – Hiperparâmetros de treinamento	38
Tabela 6 – Classificador Controle) — Resultados no conjunto de teste	43
Tabela 7 – ITA sem segmentador — Resultados no conjunto de teste	44
Tabela 8 – ITA com segmentador — Resultados no conjunto de teste	44
Tabela 9 – Comparação do desempenho no conjunto de teste entre os cenários avaliados.	45

LISTA DE ABREVIATURAS E SIGLAS

ITA	Individual Typology Angle
USP	Universidade de São Paulo
USPSC	Campus USP de São Carlos

SUMÁRIO

1	INTRODUÇÃO	25
1.1	Referencial Teórico	28
1.1.1	Escala de Fitzpatrick	28
1.1.2	Individual Typology Angle (ITA)	28
1.1.3	Segmentação de Imagens e Redes U-Net	29
1.1.4	Classificadores Baseados em Árvores: Random Forest	30
2	METODOLOGIA	33
2.1	Desenho experimental e cenários avaliados	33
2.2	Bancos de dados	34
2.2.1	HAM10000	34
2.2.1.1	Particionamento em treino, validação e teste	35
2.2.2	MSKCC Skin Tone Labeling	36
2.2.2.1	Split mestre congelado	36
2.3	Segmentação: treinamento e ajuste fino da U-Net	37
2.4	Definição da ROI de pele saudável e extração de atributos ITA	40
2.5	Treinamento dos classificadores de fotótipo (Random Forest)	41
2.6	Framework computacional e ambiente experimental	41
2.6.1	Ferramentas e bibliotecas	41
2.6.2	Ambiente computacional e reprodutibilidade	42
3	RESULTADOS	43
3.1	Desempenho dos classificadores	43
3.1.1	Cenário Controle	43
3.1.2	ITA sem segmentação	44
3.1.3	ITA com segmentação	44
3.2	Comparação entre os cenários	45
3.2.1	Acurácia e acurácia balanceada	45
3.2.2	Matrizes de confusão	45
3.3	Análise das distribuições do ITA	47
3.3.1	Exemplos qualitativos	47
4	DISCUSSÃO	51
5	CONCLUSÃO	53
5.1	Trabalhos Futuros	53

REFERÊNCIAS 55

1 INTRODUÇÃO

A aplicação de Inteligência Artificial (IA) no diagnóstico de doenças dermatológicas tem demonstrado resultados promissores, alcançando níveis de desempenho comparáveis aos de especialistas humanos em diferentes tarefas. No entanto, um desafio central permanece na manutenção de níveis adequados de acurácia em populações com diferentes tonalidades de pele, uma vez que variações na pigmentação cutânea podem influenciar tanto a qualidade da imagem quanto a interpretação automatizada dos padrões dermatoscópicos.

A avaliação da tonalidade da pele, nesse contexto, é comumente realizada por meio da escala de Fitzpatrick, proposta em 1975 com o objetivo de estimar a resposta da pele à exposição solar (Fitzpatrick, 1975). Originalmente descrita com seis fotótipos (I a VI), sua aplicação inicial concentrou-se majoritariamente em indivíduos de fotótipos mais claros (I a IV), historicamente mais representados em populações caucasianas. Posteriormente, os fotótipos V e VI passaram a ser mais amplamente reconhecidos, buscando contemplar indivíduos com tons de pele mais escuros (Alchorne; colaboradores, 2024).

Apesar de sua ampla utilização clínica, observa-se que a anotação explícita da tonalidade da pele é rara em bancos de dados dermatológicos amplamente empregados no treinamento de algoritmos de IA. A ausência dessas anotações limita a avaliação da diversidade de tons de pele presentes nas amostras e dificulta a análise sistemática de vieses associados ao desempenho dos modelos (Groh *et al.*, 2022). Como consequência, algoritmos treinados nesses conjuntos de dados podem apresentar menor precisão preditiva para indivíduos com tons de pele sub-representados, reforçando desigualdades já existentes (Adamson; Smith, 2018).

Nesse cenário, torna-se fundamental investigar estratégias metodológicas capazes de inferir a tonalidade da pele a partir das próprias imagens dermatoscópicas, de modo a ampliar a análise da representatividade dos dados e contribuir para a mitigação de vieses em algoritmos dermatológicos. Uma abordagem amplamente explorada na literatura consiste no uso do *Individual Typology Angle* (ITA), métrica contínua derivada do espaço de cor CIELAB, que permite caracterizar a tonalidade da pele a partir da distribuição cromática dos pixels da imagem.

No entanto, o cálculo do ITA não resulta em um valor único, mas sim em uma distribuição de medidas, uma vez que pode ser estimado pixel a pixel. Essa característica permite a utilização de estatísticas descritivas como médias, medianas, percentis e medidas de dispersão, para representar de forma robusta a tonalidade global da pele em uma imagem. Diante disso, surge uma questão metodológica relevante: *é necessário restringir essa análise apenas à região de pele saudável, por meio de segmentação, ou a imagem*

completa já fornece informações equivalentes para a estimativa do fotótipo?

Assim, a pergunta de pesquisa que orienta este trabalho pode ser formulada da seguinte forma: *o uso de máscaras binárias para segmentar a pele saudável melhora de forma significativa a estimativa da escala de Fitzpatrick quando comparado ao uso direto da imagem dermatoscópica completa?* Parte-se da hipótese de que a segmentação pode promover ganhos marginais ao reduzir ruídos e artefatos visuais, mas que estatísticas robustas do ITA calculadas sobre a imagem integral sejam capazes de preservar a informação cromática relevante dentro de uma margem de erro aceitável.

O objetivo geral deste trabalho é contribuir para a mitigação de vieses em algoritmos de diagnóstico dermatológico, por meio da análise da representatividade de tons de pele em bancos de dados de imagens dermatoscópicas. Como objetivo específico, busca-se avaliar o impacto do uso de máscaras binárias para segmentar a pele saudável na tarefa de estimar a escala de Fitzpatrick, comparando cenários com e sem segmentação. Para fins de contraste metodológico, também é treinado um classificador de controle baseado exclusivamente em atributos originais do banco de dados.

A Figura 1, a Figura 2 e a Figura 3 apresentam exemplos de imagens dermatoscópicas utilizadas neste estudo.




Figura 1 – Foto dermatoscópica. ID: ISIC0024344 Fonte: Skin Cancer MNIST: HAM10000 Disponível em <https://www.kaggle.com/datasets/kmader/skin-cancer-mnist-ham10000>




Figura 2 – Foto dermatoscópica. ID: ISIC0024384 Fonte: Skin Cancer MNIST: HAM10000
Disponível em <https://www.kaggle.com/datasets/kmader/skin-cancer-mnist-ham10000>



Figura 3 – Foto dermatoscópica. ID: ISIC0024431 Fonte: Skin Cancer MNIST: HAM10000
Disponível em <https://www.kaggle.com/datasets/kmader/skin-cancer-mnist-ham10000>

1.1 Referencial Teórico

1.1.1 Escala de Fitzpatrick

A escala de fotótipos cutâneos de Fitzpatrick foi proposta em 1975 por Thomas B. Fitzpatrick, da Harvard Medical School, com o objetivo de estimar a resposta da pele à radiação ultravioleta (UV), especialmente para orientar doses de fototerapia (Fitzpatrick, 1975). Originalmente concebida como um instrumento clínico baseado em questionário, a escala classifica indivíduos em seis fotótipos (I a VI), de acordo com características fenotípicas e reações à exposição solar.

Embora amplamente utilizada na prática clínica e em estudos dermatológicos, a escala de Fitzpatrick apresenta limitações conhecidas, sobretudo relacionadas à sua subjetividade e à dependência da avaliação humana. Essas limitações tornam-se ainda mais evidentes quando a escala é empregada como referência em bancos de dados destinados ao treinamento de algoritmos de Inteligência Artificial, nos quais a anotação do fotótipo pode ser inconsistente ou inexistente (Groh *et al.*, 2022).

Apesar dessas restrições, a escala permanece como uma referência consolidada na literatura, sendo frequentemente utilizada como variável-alvo em estudos que investigam vieses e desigualdades em algoritmos dermatológicos. Nesse sentido, compreender suas propriedades, limitações e contexto de aplicação é fundamental para interpretar adequadamente os resultados de modelos que buscam estimar o fotótipo de pele a partir de imagens.

Tabela 1 – Classificação da Escala de Fitzpatrick

Pontuação total	Fotótipo	Característica típica
0 – 6	I	Sempre queima, nunca bronzeia
7 – 12	II	Frequentemente queima, bronzeia pouco
13 – 18	III	Às vezes queima, bronzeia gradualmente
19 – 24	IV	Raramente queima, bronzeia bem
25 – 30	V	Quase nunca queima, pele escura
31 – 36	VI	Nunca queima, pele muito escura

1.1.2 Individual Typology Angle (ITA)

O *Individual Typology Angle* (ITA) é uma métrica contínua proposta para a caracterização objetiva da tonalidade da pele a partir de informações cromáticas extraídas de imagens (Commission Internationale de l'Éclairage (CIE), 1976). Diferentemente da escala de Fitzpatrick, o ITA não depende de avaliação subjetiva, sendo calculado diretamente a partir de componentes do espaço de cor CIELAB.

O espaço CIELAB, padronizado pela Comissão Internacional de Iluminação (CIE), foi desenvolvido para representar cores de forma perceptualmente uniforme, aproximando-se

da maneira como o olho humano percebe diferenças cromáticas (Commission Internationale de l'Éclairage (CIE), 1976). Ele é definido pelas componentes L^* (luminosidade), a^* (eixo verde-vermelho) e b^* (eixo azul-amarelo), sendo amplamente adotado em aplicações biomédicas.

O cálculo do ITA pode ser dado a partir da fórmula:

$$\text{ITA} = \arctan\left(\frac{L^* - 50}{b^*}\right) \times \frac{180}{\pi}.$$

A partir dessas componentes, o ITA pode ser calculado por meio de uma relação trigonométrica entre luminosidade e cromaticidade, resultando em um valor angular que se correlaciona com a tonalidade da pele. Estudos prévios demonstraram que intervalos de valores de ITA podem ser associados a categorias aproximadas de tom de pele, estabelecendo uma ponte conceitual entre métricas contínuas e classificações discretas (Chardon; Crétois; Hourseau, 1991; Kinyanjui *et al.*, 2019).

Contudo, investigações recentes indicam que a correspondência entre ITA e fotótipos de Fitzpatrick não é exata, devendo ser interpretada como uma aproximação e não como equivalência direta (Osto *et al.*, 2022). Ainda assim, o ITA se apresenta como uma ferramenta relevante para análises comparativas e estudos de viés, sobretudo por permitir a exploração estatística da tonalidade da pele em grandes conjuntos de imagens.

Na tabela 2 é possível ver um mapeamento de graus ITA de uma imagem para tons de pele segundo definido por Chardon *et al.* (Chardon; Crétois; Hourseau, 1991).

Tabela 2 – Classificação da tonalidade da pele com base no ITA (Individual Typology Angle)

Intervalo ITA (°)	Categoria de tonalidade
> 55	Muito clara
41 – 55	Clara
28 – 41	Clara média
10 – 28	Média
-30 – 10	Escura
< -30	Muito escura

1.1.3 Segmentação de Imagens e Redes U-Net

A segmentação de imagens consiste na identificação e isolamento de regiões de interesse relevantes para uma determinada tarefa de análise. Em dermatologia computacional, técnicas de segmentação são frequentemente utilizadas para separar lesões cutâneas, pele saudável e artefatos visuais, com o objetivo de reduzir ruídos e melhorar a qualidade das informações extraídas das imagens.

Entre as arquiteturas mais utilizadas nesse contexto destaca-se a U-Net, uma rede neural convolucional proposta por Ronneberger *et al.* (Ronneberger; Fischer; Brox, 2015).

Sua estrutura em formato de “U” combina etapas de contração e expansão, permitindo a captura de informações contextuais globais sem perda significativa de resolução espacial.

As conexões de atalho entre camadas simétricas do *encoder* e do *decoder* constituem um dos principais diferenciais da U-Net, favorecendo a preservação de detalhes finos e tornando a arquitetura particularmente adequada para aplicações biomédicas, incluindo radiologia, histopatologia e dermatologia (Liu *et al.*, 2025).

No contexto deste trabalho, a segmentação é relevante como estratégia potencial para isolar regiões de pele saudável, removendo lesões e artefatos que poderiam influenciar a estimativa da tonalidade cutânea. A real contribuição dessa etapa, entretanto, permanece uma questão metodológica em aberto, que motiva a investigação conduzida neste estudo.

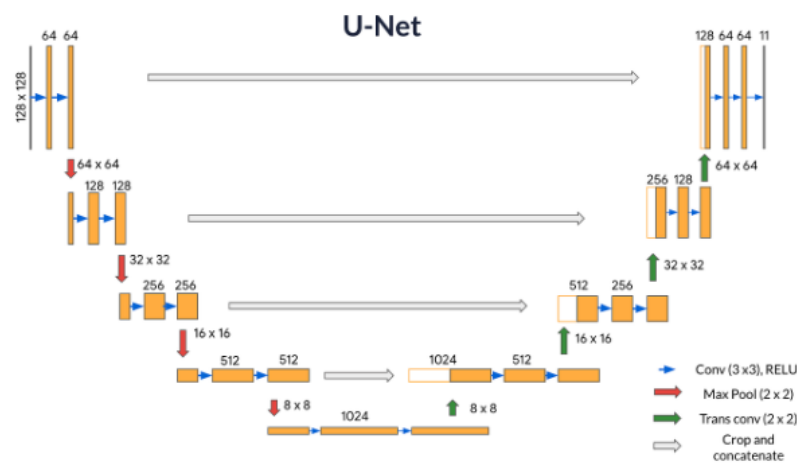


Figura 4 – Arquitetura da rede U-Net. Fonte: https://miro.medium.com/v2/resize:fit:1358/1*0qJdnSxkerwZPCWVdLPpHw.png

1.1.4 Classificadores Baseados em Árvores: Random Forest

O Random Forest é um método de aprendizado supervisionado baseado em *ensembles* de árvores de decisão, proposto por Breiman (Breiman, 2001). A técnica combina múltiplos modelos treinados sobre subconjuntos aleatórios de dados e variáveis, agregando suas previsões por votação majoritária.

Essa abordagem reduz o risco de sobreajuste e confere maior estabilidade aos modelos, sendo particularmente adequada para dados tabulares e problemas multiclasse. Além disso, o Random Forest apresenta vantagens de interpretabilidade em relação a modelos mais complexos, permitindo a análise da importância relativa dos atributos utilizados na decisão.

Em aplicações biomédicas, o Random Forest é amplamente empregado devido à sua robustez frente a dados heterogêneos e desbalanceados, características comuns em bancos de dados clínicos e de imagens anotadas. Essas propriedades justificam sua utilização como

classificador neste estudo.

2 METODOLOGIA

Este capítulo descreve o desenho experimental, os bancos de dados empregados e os procedimentos adotados para estimar a tonalidade de pele e treinar classificadores da escala de Fitzpatrick. O foco está na descrição reprodutível do pipeline, incluindo os cenários comparados, o treinamento do segmentador, a extração de atributos baseados em ITA e a configuração dos modelos de classificação.

2.1 Desenho experimental e cenários avaliados

O estudo foi estruturado em três cenários experimentais, com o objetivo de isolar o efeito da segmentação de pele saudável na extração de atributos cromáticos e, conseqüentemente, na tarefa de classificação do fotótipo de Fitzpatrick.

Cenário 1 (ITA sem segmentação). Neste cenário, o ITA é calculado diretamente sobre a imagem dermatoscópica completa, preservando ruídos e artefatos eventualmente presentes. O fluxo geral encontra-se ilustrado na Figura 5.

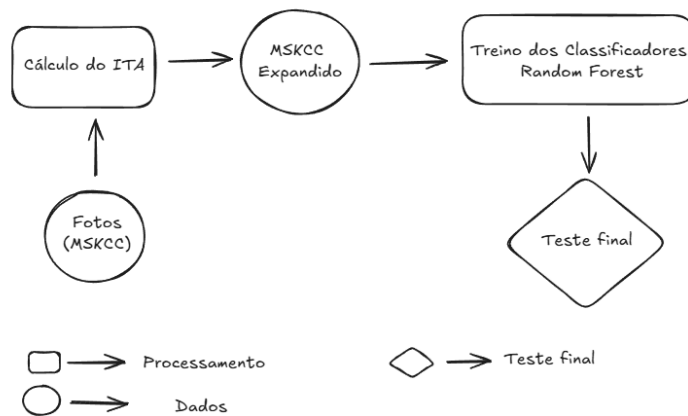


Figura 5 – Cenário 1: pipeline sem segmentação (ITA calculado sobre a imagem completa).

Cenário 2 (ITA com segmentação). Neste cenário, introduz-se uma etapa de segmentação para isolar a região de pele saudável, excluindo a lesão e regiões não informativas (e.g., borda do dermatoscópio), com o objetivo de obter medidas cromáticas menos afetadas por artefatos. O pipeline correspondente está representado na Figura 6.

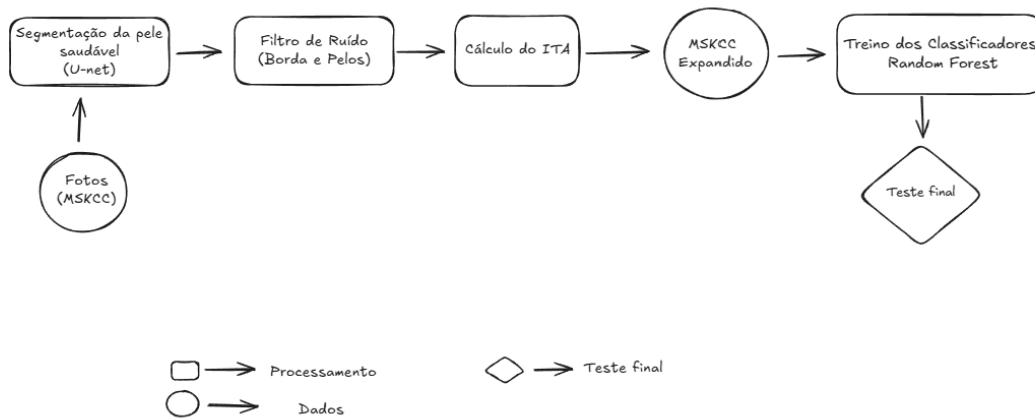


Figura 6 – Cenário 2: pipeline com segmentação (ITA calculado em ROI de pele saudável).

Cenário 3 (Controle). Como referência, treinou-se um classificador utilizando apenas atributos nativos do banco de dados (sem cálculo de ITA), com o objetivo de fornecer uma linha de base para comparação com os cenários baseados em ITA.

2.2 Bancos de dados

2.2.1 HAM10000

Foi utilizado o *HAM10000* (Human Against Machine with 10000 training images), um banco de dados público amplamente empregado em dermatologia computacional e disponível no *Harvard Dataverse* e no Kaggle. Ele contém 10.015 imagens dermatoscópicas em RGB (600×450 pixels, 8 bits por canal), provenientes de múltiplas fontes clínicas, incluindo prática privada em Viena (Áustria) e o Hospital Clínico de Queensland (Austrália) (Tschandl; Rosendahl; Kittler, 2018).

Além das imagens, o conjunto fornece metadados estruturados com atributos como *image_id*, *lesion_id*, *dx*, *age_approx*, *sex* e *localization*. Para apoiar o particionamento e auditoria do *split*, foram derivadas variáveis adicionais: calculou-se a área da lesão em pixels (*lesion_area_px*) e esta foi categorizada em tercís (*area_bin* = S/M/L). Em seguida, concatenou-se *dx* e *area_bin* para compor a variável *strata*, utilizada para garantir diversidade clínica e visual entre os subconjuntos.

O banco dispõe de máscaras de segmentação binária da lesão (PNG, 1 bit), fornecidas em um conjunto auxiliar (*HAM10000 Lesion Segmentations*) disponível no Kaggle (Tschandl *et al.*, 2020). Essas máscaras foram utilizadas como *ground truth* para o treinamento do segmentador.

2.2.1.1 Particionamento em treino, validação e teste

O particionamento em **train**, **val** e **test** foi realizado em duas etapas por *GroupShuffleSplit*, utilizando *lesion_id* como agrupador para evitar vazamento entre subconjuntos. Inicialmente, 10% do total foi reservado para teste. Em seguida, a partir do remanescente, 10% do total foi destinado à validação.

Para preservar a distribuição global dos estratos, utilizou-se a distância *L1*, definida por:

$$\text{Gap}(P, Q) = \sum_i |P_i - Q_i|,$$

onde *P* representa a distribuição do conjunto completo e *Q* a distribuição do subconjunto avaliado. O *split* final foi escolhido pelo menor *gap* dentro de tolerância estabelecida.

A Tabela 3 apresenta a distribuição percentual dos estratos (*dx + area_bin*) após o *split*. As tabelas e relatórios auxiliares (histogramas e boxplots da variável *lesion_area_px*) foram utilizados para auditoria do balanceamento das divisões.

Tabela 3 – Distribuição percentual dos estratos (diagnóstico + área) no HAM10000 após split em TRAIN, VAL e TEST.

strata	ALL_%	TRAIN_%	VAL_%	TEST_%
akiec__L	2.08	1.85	3.28	2.72
akiec__M	0.85	0.72	1.29	1.41
akiec__S	0.34	0.26	0.70	0.60
bcc__L	1.70	1.80	0.90	1.71
bcc__M	1.75	1.73	1.89	1.71
bcc__S	1.69	1.66	2.29	1.31
bkl__L	5.16	5.30	5.07	4.13
bkl__M	3.32	3.38	3.28	2.82
bkl__S	2.50	2.46	2.89	2.42
df__L	0.51	0.49	0.70	0.50
df__M	0.44	0.44	0.60	0.30
df__S	0.20	0.17	0.20	0.40
mel__L	5.43	5.44	5.77	5.04
mel__M	3.08	3.03	2.79	3.73
mel__S	2.61	2.57	2.99	2.52
nv__L	18.96	19.07	17.51	19.54
nv__M	23.31	23.34	23.48	22.86

Continua na próxima página

Tabela 3 – Distribuição percentual dos estratos (diagnóstico + área) no HAM10000 após split em TRAIN, VAL e TEST (continuação).

strata	ALL_%	TRAIN_%	VAL_%	TEST_%
nv__S	24.68	24.87	22.49	25.38
vasc__L	0.16	0.16	0.30	0.00
vasc__M	0.27	0.26	0.50	0.10
vasc__S	0.99	1.00	1.09	0.81

Ressalta-se que o objetivo central do trabalho não é a segmentação da lesão em si, mas a obtenção de uma ROI de pele saudável (região negativa da máscara). Assim, o uso de `dx` em `strata` foi adotado como mecanismo de controle para diversidade visual, e não como requisito de balanceamento perfeito por diagnóstico.

2.2.2 MSKCC Skin Tone Labeling

O conjunto *MSKCC Skin Tone Labeling* é um banco de dados público disponibilizado pelo Memorial Sloan Kettering Cancer Center (MSKCC) e acessível via TCIA. Ele contém aproximadamente 4.870 imagens dermatoscópicas em RGB (resolução variável, tipicamente entre 768×512 e 1024×768 pixels, 8 bits por canal) (Memorial Sloan Kettering Cancer Center, 2025).

O conjunto inclui metadados com *image_id*, *patient_id*, *fitzpatrick_skin_type* (classes I–VI, anotação manual), *diagnosis*, *age_approx*, *sex* e *image_path*.

2.2.2.1 Split mestre congelado

A divisão do MSKCC foi conduzida por um *split mestre* único e “congelado”, aplicado de forma idêntica a todos os cenários. Com *seed* fixa, alocou-se aproximadamente 20% dos IDs para *test*, 10% para *val* e o restante para *train*. A atribuição foi realizada no nível do identificador (ID), assegurando que observações do mesmo ID permanecessem no mesmo subconjunto, evitando vazamento.

A Tabela 4 apresenta a distribuição percentual das classes Fitzpatrick nos *splits*.

Classe	Geral (%)	Train (%)	Val (%)	Test (%)
I	16.1713	16.1347	18.4426	15.1639
II	19.4712	19.5608	17.0082	20.3893
III	16.2738	16.5154	15.3689	15.8811
IV	16.0484	15.6369	17.4180	16.8033
V	16.6633	16.9839	16.1885	15.7787
VI	15.3720	15.1684	15.5738	15.9836

Tabela 4 – Distribuição percentual das classes no conjunto completo e nos *splits* de treinamento, validação e teste.

Para reduzir vieses e evitar *atalhos preditivos*, no cenário Controle foram removidas variáveis consideradas indevidamente informativas (e.g., *age_approx*) após auditoria. Nos cenários de ITA, a classificação foi restrita exclusivamente aos atributos derivados do cálculo do ITA.

2.3 Segmentação: treinamento e ajuste fino da U-Net

Esta seção descreve o treinamento do segmentador utilizado no Cenário 2, responsável por inferir máscaras binárias da lesão a partir das imagens dermatoscópicas.

A arquitetura adotada foi uma U-Net com *encoder* inicializado com pesos da ResNet-34. Os pesos do *encoder* foram mantidos congelados nas três primeiras épocas e descongelados a partir da época 4, enquanto o *decoder* foi treinado do zero utilizando o HAM10000 e suas máscaras correspondentes.

Durante o treinamento, buscou-se mitigar riscos de sobreajuste e instabilidade numérica por meio de estratégias complementares: (i) particionamento com controle de vazamento por paciente e *data augmentation*; (ii) *early stopping*; (iii) *weight decay* (Loshchilov; Hutter, 2017); (iv) função de perda combinada (*BCEWithLogits + Dice Loss*); (v) precisão mista e *gradient clipping* (Pascanu; Mikolov; Bengio, 2013); (vi) *learning rate scheduling* (Smith, 2017); e (vii) calibração do limiar por *threshold tuning* visando maximizar Dice no conjunto de validação.

A Tabela 5 sumariza os hiperparâmetros de treinamento.

Tabela 5 – Hiperparâmetros de treinamento

Parâmetro	Valor
Tamanho da imagem	256×256
Tamanho do lote	8
Épocas	40
Épocas com encoder congelado	3
Taxa de aprendizado do decoder	1×10^{-3}
Taxa de aprendizado do encoder	5×10^{-4}
Decaimento de peso	1×10^{-4}
Clipping de gradiente	1.0
Paciência do early stopping	4
Semente aleatória	42
Varredura de limiares	0.30 a 0.70
Modelo	U-Net com ResNet34
Função de perda	BCEWithLogits + DiceLoss
Otimizador	AdamW
Scheduler	ReduceLROnPlateau

As Figuras 7, 8 e 9 apresentam as curvas de treinamento e a varredura de limiar realizada no conjunto de validação.

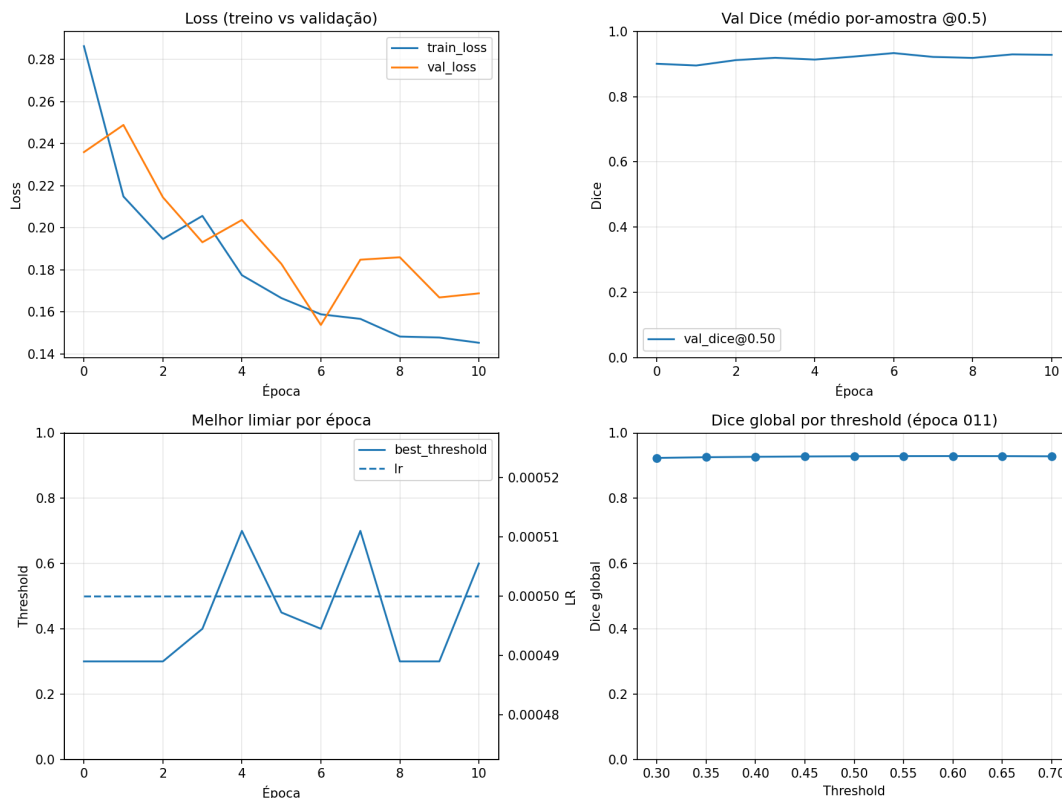


Figura 7 – Métricas de treino

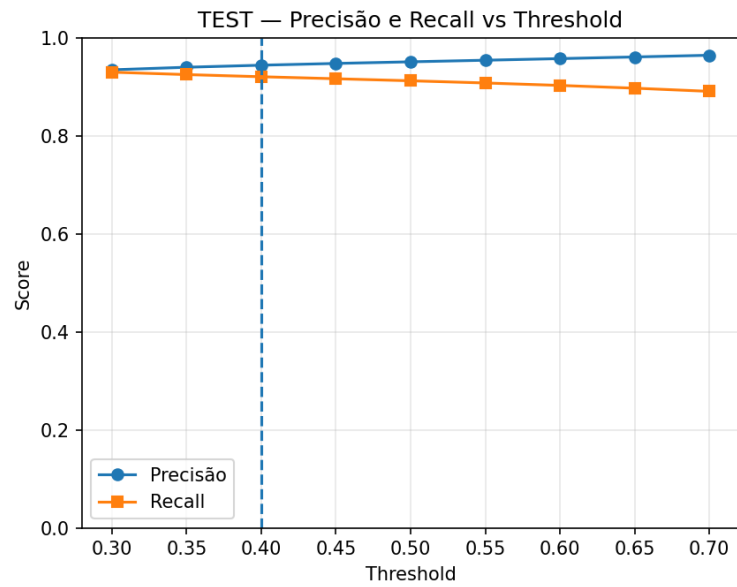


Figura 8 – Precisão e recall

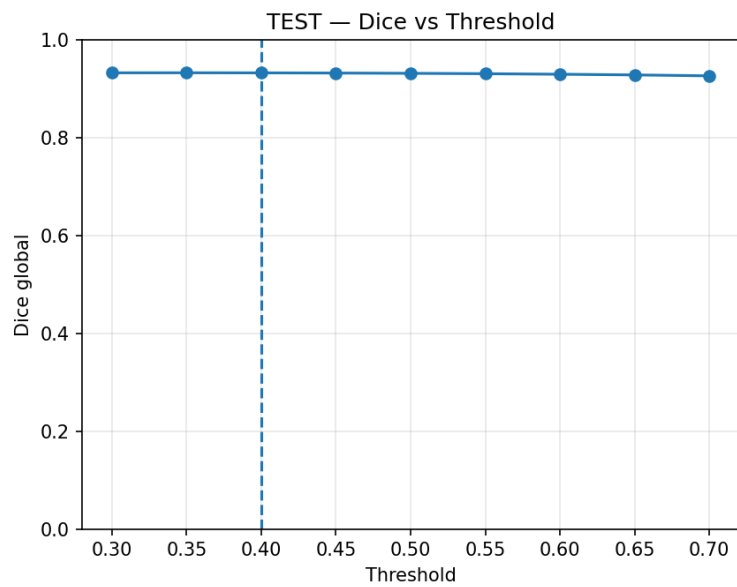


Figura 9 – Dice vs Threshold

Exemplos qualitativos de máscaras preditas e suas correspondentes referências podem ser observados nas Figuras 10, 11 e 12.




Figura 10 – Máscara de lesão predita




Figura 11 – Máscara de lesão predita




Figura 12 – Máscara de lesão predita

2.4 Definição da ROI de pele saudável e extração de atributos ITA

Nesta etapa, a distribuição do ITA é estimada para cada imagem e resumida por estatísticas descritivas utilizadas como entrada do classificador de fotótipos.

No Cenário 2 (*ITA com segmentador*), a ROI de pele saudável é obtida a partir da máscara de lesão predita, definindo a região negativa da máscara como pele saudável. Além disso, foram aplicados filtros adicionais para reduzir artefatos visuais, incluindo: (i) remoção da borda do dermatoscópio por detecção de regiões periféricas de baixa intensidade no canal V do HSV e operações morfológicas de fechamento; e (ii) remoção de pelos via transformações *black-hat* e *top-hat* (na imagem invertida), combinação de máscaras, limiarização (Otsu) e dilatação morfológica para englobar os fios. A ROI final foi definida pelos pixels que não pertenciam à máscara de lesão, nem à máscara de borda, nem à máscara de pelos.

No Cenário 1 (*ITA sem segmentação*), o cálculo do ITA é realizado diretamente sobre a imagem original, preservando ruídos e artefatos.

Em ambos os cenários, a distribuição do ITA por imagem foi resumida por medidas de tendência central e dispersão (e.g., percentis, quartis, mediana e variância), além de medidas de forma, como assimetria (*skewness*) e curtose (*kurtosis*). Essas estatísticas compõem o vetor de atributos utilizado na etapa de classificação.

2.5 Treinamento dos classificadores de fotótipo (Random Forest)

A classificação dos fotótipos Fitzpatrick (I–VI) foi realizada por meio de modelos de *Random Forest*, treinados separadamente para cada cenário (Controle, ITA sem segmentação e ITA com segmentação), utilizando o *split mestre* congelado.

O Random Forest foi escolhido por sua robustez em dados tabulares e por capturar relações não lineares e interações entre atributos derivados do ITA, sem exigir normalização das variáveis e com boa estabilidade frente a desbalanceamentos.

O pré-processamento e o ajuste do modelo foram estruturados em *pipelines*, assegurando que imputações e codificações fossem ajustadas exclusivamente nos dados de treino do cenário correspondente, prevenindo vazamento de informação. A avaliação foi realizada com *balanced accuracy*, matriz de confusão e análise de importância de atributos, conforme detalhado no Capítulo de Resultados.

2.6 Framework computacional e ambiente experimental

Esta seção descreve o ambiente de implementação e as principais ferramentas utilizadas para execução dos experimentos, com ênfase em reprodutibilidade e padronização dos procedimentos computacionais.

2.6.1 Ferramentas e bibliotecas

O treinamento do segmentador foi implementado em PyTorch, framework amplamente utilizado em pesquisa em visão computacional, por oferecer flexibilidade na definição de modelos e controle explícito do processo de treinamento. Para acelerar a execução em GPU e aumentar a eficiência computacional, foram utilizados recursos do ecossistema CUDA/cuDNN e suporte a *automatic mixed precision* (AMP) quando aplicável.

A etapa de classificação foi conduzida com o *Random Forest* disponível no `scikit-learn`. O fluxo de pré-processamento e treinamento foi estruturado em *pipelines*, garantindo que etapas como imputação e codificação fossem ajustadas exclusivamente no conjunto de treino de cada cenário, mitigando risco de vazamento de informação entre subconjuntos.

2.6.2 Ambiente computacional e reprodutibilidade

Os experimentos foram conduzidos em ambiente Windows 11, com Python 3.12 e suporte a GPU NVIDIA. As versões das bibliotecas foram rigidamente controladas para garantir reprodutibilidade. A base do ambiente incluiu *numpy 1.26.4* e *pandas 2.2.2* para manipulação de dados; *tqdm 4.66.4* para monitoramento de progresso; *opencv-python 4.10.0.84*, *Pillow 10.4.0* e *scikit-image 0.24.0* para pré-processamento de imagens; *torch 2.2.2* e *torchvision 0.17.2* para definição e treino do segmentador; *scikit-learn 1.5.2* para implementação do classificador e métricas; e *matplotlib 3.9.2* e *seaborn 0.13.2* para visualizações e análises gráficas.

Para assegurar consistência entre os cenários, foram mantidos fixos o *split* mestre, as sementes aleatórias e o procedimento de avaliação, permitindo que as diferenças observadas entre abordagens fossem atribuídas ao método analisado, e não a variações de execução.

3 RESULTADOS

Este capítulo apresenta os resultados obtidos a partir da aplicação dos pipelines propostos para a estimativa do fotótipo de Fitzpatrick. São reportados os desempenhos dos classificadores treinados nos diferentes cenários avaliados, bem como análises comparativas baseadas em métricas quantitativas e evidências visuais. A interpretação dos achados é discutida no capítulo subsequente.

3.1 Desempenho dos classificadores

Os classificadores foram avaliados no conjunto de teste mantido completamente separado das etapas de treinamento e validação. Para todos os cenários, são reportadas métricas de precisão, revocação, F1-score por classe, acurácia global e acurácia balanceada, permitindo uma análise detalhada do comportamento dos modelos frente às diferentes classes de fotótipo.

3.1.1 Cenário Controle

No cenário Controle, o classificador foi treinado exclusivamente com atributos nativos do banco de dados, sem a utilização de medidas derivadas do ITA. Esse experimento foi conduzido com o objetivo de estabelecer uma linha de base para comparação com os cenários baseados em atributos cromáticos.

Tabela 6 – Classificador Controle) — Resultados no conjunto de teste

Classe	Precision	Recall	F1-score	Support
I	0.08	0.02	0.03	148
II	0.30	0.59	0.40	199
III	0.30	0.75	0.43	155
IV	0.26	0.10	0.15	164
V	0.00	0.00	0.00	154
VI	0.29	0.18	0.22	156
Accuracy	0.29 (976 amostras)			
Balanced Acc.	0.2752			
Macro Avg	0.21	0.28	0.21	976
Weighted Avg	0.21	0.29	0.22	976

Os resultados obtidos evidenciam desempenho limitado do modelo, com valores reduzidos de acurácia e acurácia balanceada, além de forte variabilidade entre as classes. Esse comportamento indica que os atributos originais, isoladamente, não são suficientes para capturar a informação necessária à correta estimativa do fotótipo de Fitzpatrick.

3.1.2 ITA sem segmentação

No segundo cenário, o classificador foi treinado a partir de estatísticas derivadas do cálculo do ITA sobre a imagem dermatoscópica completa, sem a aplicação de segmentação ou remoção explícita de artefatos.

Tabela 7 – ITA sem segmentador — Resultados no conjunto de teste

Classe	Precision	Recall	F1-score	Support
I	0.34	0.34	0.34	148
II	0.39	0.47	0.42	199
III	0.32	0.32	0.32	155
IV	0.43	0.33	0.37	164
V	0.46	0.47	0.46	154
VI	0.53	0.51	0.52	156
Accuracy	0.41 (976 amostras)			
Balanced Acc.	0.4062			
Macro Avg	0.41	0.41	0.41	976
Weighted Avg	0.41	0.41	0.41	976

Em comparação ao cenário Controle, observa-se um aumento consistente nas métricas globais de desempenho, incluindo acurácia e acurácia balanceada. O ganho é observado de forma relativamente homogênea entre as classes, sugerindo que o ITA incorpora informações relevantes associadas à tonalidade da pele.

3.1.3 ITA com segmentação

No terceiro cenário, as estatísticas de ITA foram extraídas exclusivamente da região de pele saudável, definida a partir da segmentação automática da lesão e da aplicação de filtros adicionais de pré-processamento.

Tabela 8 – ITA com segmentador — Resultados no conjunto de teste

Classe	Precision	Recall	F1-score	Support
I	0.35	0.36	0.36	148
II	0.36	0.45	0.40	199
III	0.37	0.32	0.34	155
IV	0.44	0.34	0.38	164
V	0.51	0.52	0.52	154
VI	0.50	0.50	0.50	156
Accuracy	0.42 (976 amostras)			
Balanced Acc.	0.4159			
Macro Avg	0.42	0.42	0.42	976
Weighted Avg	0.42	0.42	0.42	976

Os resultados mostram desempenho ligeiramente superior em relação ao cenário sem segmentação, com aumento marginal nas métricas globais. A distribuição dos erros

entre as classes permanece semelhante, indicando que o uso do segmentador não altera de forma substancial o padrão de confusões entre fotótipos adjacentes.

3.2 Comparação entre os cenários

A comparação direta entre os três cenários evidencia diferenças claras entre o modelo de referência e aqueles baseados em ITA, bem como diferenças sutis entre os pipelines com e sem segmentação.

3.2.1 Acurácia e acurácia balanceada

Tabela 9 – Comparação do desempenho no conjunto de teste entre os cenários avaliados.

Cenário	Accuracy	Balanced accuracy
Controle (atributos nativos)	0.29	0.2752
ITA sem segmentação	0.41	0.4062
ITA com segmentação (pele saudável)	0.42	0.4159

Observa-se que ambos os cenários baseados em ITA apresentam desempenho superior ao cenário Controle. A diferença entre os pipelines com e sem segmentação é pequena, situando-se dentro de uma margem estreita, o que indica que o impacto da segmentação automática na métrica global é limitado.

3.2.2 Matrizes de confusão

Para uma análise mais detalhada do comportamento dos classificadores, foram geradas matrizes de confusão no conjunto de teste para cada cenário avaliado.

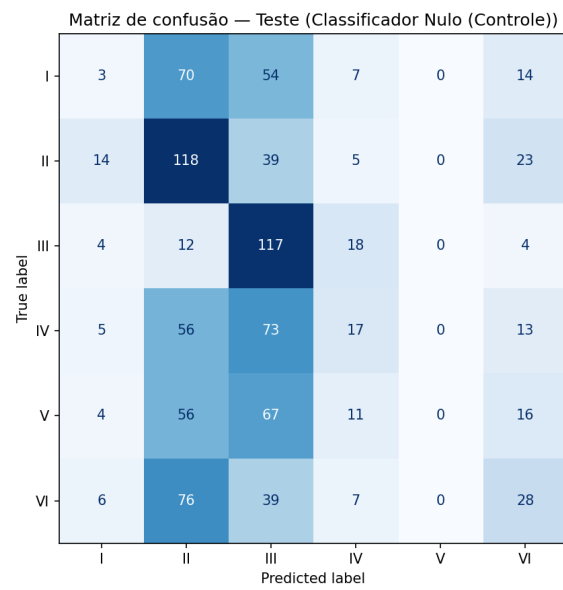


Figura 13 – Matriz de confusão Classificador Controle treinado somente com dados originais

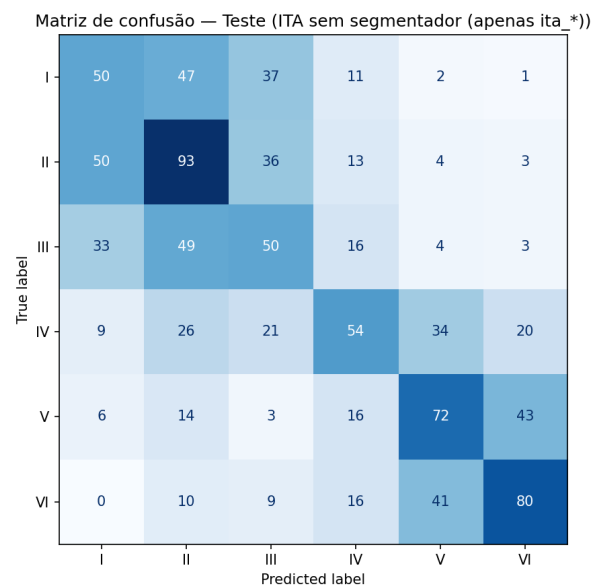


Figura 14 – Matriz de confusão do classificador sem ITA com segmentação de pele saudável




Figura 15 – Matriz de confusão do classificador com ITA com segmentação de pele saudável

As matrizes evidenciam que os principais erros ocorrem entre classes adjacentes da escala de Fitzpatrick, padrão consistente entre os três cenários. A introdução do ITA reduz a taxa de confusões extremas, enquanto a segmentação apresenta efeito discreto sobre essa distribuição.

3.3 Análise das distribuições do ITA

Além das métricas de classificação, foram analisadas as distribuições do ITA obtidas em nível de imagem, com o objetivo de avaliar o impacto da segmentação sobre a extração dos atributos cromáticos.

3.3.1 Exemplos qualitativos

A Figura 16 apresenta um exemplo representativo de imagem dermatoscópica utilizada na análise.



Figura 16 – Imagem ID: ISIC 0132369

As Figuras 17 e 18 mostram, respectivamente, as distribuições do ITA calculadas sem e com segmentação para essa imagem.




Figura 17 – ISIC 0132369: Distribuição ITA sem segmentação

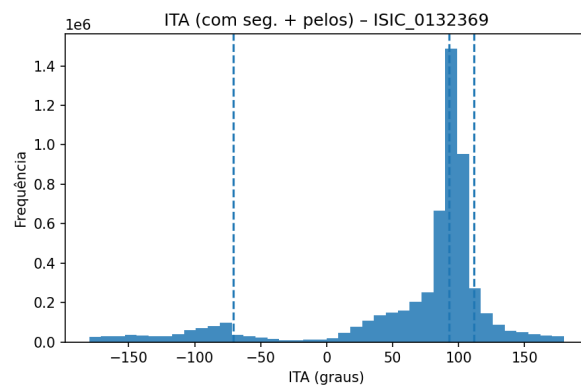


Figura 18 – ISIC 0132369: Distribuição ITA com segmentação

De forma análoga, um segundo exemplo é apresentado para ilustrar a consistência do comportamento observado.



Figura 19 – Imagem ID: ISIC 0107306




Figura 20 – Imagem ID: ISIC 0107306: Distribuição ITA sem segmentação




Figura 21 – Imagem ID: ISIC 0107306: Distribuição ITA com segmentação

De modo geral, as distribuições obtidas com e sem segmentação apresentam formatos semelhantes, com diferenças sutis nos valores extremos e na dispersão, reforçando a observação de que a segmentação exerce influência limitada sobre o conjunto de estatísticas derivadas do ITA.

4 DISCUSSÃO

Os resultados obtidos neste trabalho indicam que o *Individual Typology Angle* (ITA), quando utilizado de forma isolada, apresenta capacidade limitada para a estimativa robusta dos fotótipos de Fitzpatrick a partir de imagens dermatoscópicas. Embora os modelos baseados em ITA tenham superado o classificador de referência, o desempenho global permaneceu moderado, sugerindo que a informação cromática, por si só, não é suficiente para capturar toda a complexidade envolvida na classificação do tom de pele.

No que se refere ao uso da segmentação da pele saudável, observou-se apenas um ganho marginal de desempenho em relação ao cenário sem segmentação. Esse resultado sugere que, no contexto específico deste estudo, a restrição da análise à região segmentada não altera substancialmente as estatísticas derivadas do ITA. Tal comportamento é consistente com a observação de que as distribuições do ITA, com e sem segmentação, apresentaram formas semelhantes, com diferenças discretas nos valores extremos.

A estabilidade das medidas de tendência central e dispersão do ITA indica que a métrica preserva características representativas da população cromática da imagem, mesmo na presença de ruídos e artefatos. Entretanto, essa estabilidade não se traduz necessariamente em maior capacidade discriminativa entre fotótipos adjacentes, o que se reflete nas confusões observadas entre classes próximas da escala de Fitzpatrick.

É importante destacar que os achados apresentados devem ser interpretados à luz das limitações do estudo. O tamanho e a diversidade das bases utilizadas, bem como a subjetividade inerente à anotação dos fotótipos, podem influenciar os resultados obtidos. Assim, a generalização das conclusões requer validação adicional em conjuntos de dados mais amplos, heterogêneos e representativos de diferentes contextos clínicos e demográficos.

5 CONCLUSÃO

Este trabalho teve como objetivo avaliar o impacto do uso de segmentação da pele saudável na estimativa do fotótipo de Fitzpatrick a partir de imagens dermatoscópicas, por meio do cálculo do *Individual Typology Angle* (ITA). Para isso, foram comparados diferentes pipelines de extração de atributos cromáticos e classificação, incluindo um cenário de referência e dois cenários baseados em ITA, com e sem segmentação.

Os resultados demonstraram que a incorporação do ITA melhora o desempenho dos classificadores em relação ao uso exclusivo de atributos nativos dos bancos de dados. Entretanto, o uso da segmentação da pele saudável resultou em ganhos apenas marginais, não alterando de forma substancial a capacidade preditiva dos modelos avaliados.

Dessa forma, conclui-se que o ITA constitui um parâmetro informativo e consistente para a análise da tonalidade da pele, mas insuficiente como critério exclusivo para a classificação do fotótipo de Fitzpatrick. O uso de segmentadores automáticos, embora tecnicamente viável, mostrou impacto limitado no contexto investigado, devendo sua adoção ser avaliada à luz do custo computacional e da complexidade adicional introduzida no pipeline.

5.1 Trabalhos Futuros

Como trabalhos futuros, recomenda-se a integração do cálculo do ITA com outros tipos de atributos, como características geométricas e texturais das imagens, bem como variáveis demográficas, de modo a compor modelos mais robustos e menos dependentes de um único parâmetro cromático.

Adicionalmente, a investigação de classificadores mais avançados, incluindo redes neurais profundas ou ensembles híbridos, pode permitir melhor exploração da combinação de múltiplas fontes de informação. A ampliação das bases de dados utilizadas, com maior diversidade de tons de pele e diagnósticos, também se mostra fundamental para melhorar a generalização dos modelos e reduzir vieses.

Por fim, estudos futuros devem avaliar o uso de segmentadores não apenas sob a ótica da acurácia, mas também considerando custo computacional, robustez e impacto de erros de segmentação, a fim de determinar a viabilidade prática de sua aplicação em pipelines clínicos reais.

REFERÊNCIAS

- ADAMSON, A. S.; SMITH, L. Machine learning in dermatology: Can we overcome the bias in skin of color? **JAMA Dermatology**, v. 154, n. 11, p. 1247–1248, 2018. Disponível em: <https://jamanetwork.com/journals/jamadermatology/article-abstract/2689168>.
- ALCHORNE, M. M. d. A.; COLABORADORES. Dermatologia na pele negra. **Anais Brasileiros de Dermatologia**, 2024. Acesso em: 06 abr. 2025. Disponível em: <https://www.scielo.br/j/abd/a/N7XSYHgsYNptLnxw5XLtb3m/>.
- BREIMAN, L. Random forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001. Disponível em: <https://link.springer.com/article/10.1023/A:1010933404324>.
- CHARDON, A.; CRÉTOIS, I.; HOURSEAU, C. Skin colour typology and suntanning pathways. **Archives of Dermatological Research**, v. 283, n. 4, p. 219–224, 1991.
- Commission Internationale de l'Éclairage (CIE). **Colorimetry**. 2nd. ed. Vienna, Austria: CIE Central Bureau, 1976. v. 15. (CIE Publication, v. 15).
- FITZPATRICK, T. B. Soleil et peau. **Journal de Médecine Esthétique**, n. 2, p. 33–34, 1975. Original em francês; título traduzido: "Sun and skin".
- GROH, M. *et al.* Towards transparency in dermatology image datasets with skin tone annotations by experts, crowds, and an algorithm. **Proceedings of the ACM on Human-Computer Interaction**, v. 6, n. CSCW2, p. 1–26, 2022. Disponível em: <https://arxiv.org/abs/2207.02942>.
- KINYANJUI, N. M. *et al.* Estimating skin tone and effects on classification performance in dermatology datasets. **arXiv preprint arXiv:1910.13268**, 2019. Presented at NeurIPS 2019 Workshop on Fair ML for Health, Vancouver, Canada. Disponível em: <https://arxiv.org/abs/1910.13268>.
- LIU, Z. *et al.* Skin lesion segmentation with a multiscale input fusion u-net incorporating res2-se and pyramid dilated convolution. **Scientific Reports**, v. 15, n. 1, p. 7975, 2025. Acesso em: 23 out. 2025. Disponível em: <https://doi.org/10.1038/s41598-025-92447-1>.
- LOSHCHILOV, I.; HUTTER, F. Decoupled weight decay regularization. **arXiv preprint arXiv:1711.05101**, 2017. Acesso em: 23 out. 2025. Disponível em: <https://doi.org/10.48550/arXiv.1711.05101>.
- Memorial Sloan Kettering Cancer Center. **MSKCC Skin Tone Labeling Dataset**. 2025. ISIC Archive. Acesso em: 23 out. 2025. Disponível em: <https://doi.org/10.34970/962049>.
- OSTO, M. *et al.* Individual typology angle and fitzpatrick skin phototypes are not equivalent in photodermatology. **Photochemistry and Photobiology**, v. 98, n. 1, p. 127–129, 2022. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/34796498/>.
- PASCANU, R.; MIKOLOV, T.; BENGIO, Y. On the difficulty of training recurrent neural networks. *In: Proceedings of the 30th International Conference on Machine Learning (ICML 2013)*. PMLR, 2013. (Proceedings of Machine Learning Research, v. 28), p. 1310–1318. Acesso em: 23 out. 2025. Disponível em: <https://proceedings.mlr.press/v28/pascanu13.html>.

RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: Convolutional networks for biomedical image segmentation. *In: Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. Springer, Cham, 2015. (Lecture Notes in Computer Science, v. 9351), p. 234–241. Acesso em: 23 out. 2025. Disponível em: https://doi.org/10.1007/978-3-319-24574-4_28.

SMITH, L. N. Cyclical learning rates for training neural networks. **arXiv preprint arXiv:1711.05101**, 2017. Acesso em: 23 out. 2025. Disponível em: <https://sands.kaust.edu.sa/classes/CS290E/F19/papers/clr.pdf>.

TSCHANDL, P. *et al.* Human–computer collaboration for skin cancer recognition. **Nature Medicine**, 2020. Acesso em: 23 out. 2025. Disponível em: <https://doi.org/10.1038/s41591-020-0942-0>.

TSCHANDL, P.; ROSENDAHL, C.; KITTLER, H. The ham10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions. **Scientific Data**, 2018. Acesso em: 23 out. 2025. Disponível em: <https://doi.org/10.1038/sdata.2018.161>.