

DESENVOLVIMENTO DE UM PROTÓTIPO DE APLICAÇÃO PARA IDENTIFICAÇÃO DE COLORAÇÃO PESSOAL UMA ABORDAGEM BASEADA EM INTELIGÊNCIA ARTIFICIAL

Maria Laura dos Santos Vieira¹, Marlon de Matos de Oliveira²

Resumo: A análise de coloração pessoal é um processo complexo, tradicionalmente subjetivo e dependente de especialistas. Este trabalho apresenta o uso de técnicas de inteligência artificial aplicadas a imagens de mulheres no desenvolvimento de um protótipo de sistema para classificação de coloração pessoal. O objetivo foi propor uma solução capaz de agrupar rostos femininos conforme as 12 cartelas do método sazonal expandido, mesmo sem dados previamente rotulados. Foram explorados dois modos de análise: Modo Rosto (imagem completa) e Modo Pele (segmentação das regiões de pele), utilizando a biblioteca MTCNN para detecção facial e extração de áreas específicas da pele. Em seguida, foram extraídas 27 características cromáticas por imagem, combinando histogramas no espaço de cores CIELAB com análise de cor dominante. As informações foram reduzidas dimensionalmente com UMAP e agrupadas por meio do algoritmo k-means. A avaliação dos resultados incluiu visualizações dos agrupamentos e uma etapa de validação qualitativa com especialistas em coloração pessoal. Apesar das limitações de participação na validação, foi possível identificar coerência visual nos clusters, especialmente no Modo Pele. O estudo demonstra a viabilidade de abordagens não supervisionadas para a classificação de coloração pessoal e sugere caminhos promissores para aprimoramentos futuros, como o uso de bases rotuladas, técnicas de aprendizado supervisionado e a ampliação da diversidade étnico-racial nas imagens analisadas.

Palavras-chave: Coloração Pessoal, Inteligência Artificial; Segmentação de Pele; Aprendizado Não Supervisionado; UMAP; k-means.

¹Curso de Ciência da Computação, Universidade do Extremo Sul Catarinense (Unesc), marialaurasvp@gmail.com

²Curso de Ciência da Computação, Universidade do Extremo Sul Catarinense (Unesc), marlon.oliveira@unesc.net

ABSTRACT: Personal color analysis is a complex process that has traditionally been subjective and dependent on specialists. This work presents the use of artificial intelligence techniques applied to images of women in the development of a prototype system for personal color classification. The goal was to propose a solution capable of grouping female faces according to the 12 palettes of the expanded seasonal method, even without the use of previously labeled data. To achieve this, two modes of analysis were explored: Face Mode (full image) and Skin Mode (segmentation of skin regions), using the MTCNN library for facial detection and extraction of specific skin areas. Next, 27 chromatic features were extracted per image, combining histograms in the CIELAB color space and dominant color analysis. This information was then dimensionally reduced using UMAP and clustered with k-means. The results were evaluated through clustering visualizations and a qualitative validation stage conducted with personal color analysis specialists. Although the validation faced limitations in participation, visual coherence within the clusters was observed, especially in Skin Mode. The study highlights the feasibility of unsupervised approaches and paves the way for future improvements with labeled datasets, supervised learning, and greater ethnic and racial diversity in the images.

Keywords: Personal Color Analysis; Artificial Intelligence; Skin Segmentation; Unsupervised Learning; UMAP; k-means.

1 INTRODUÇÃO

As cores desempenham um papel de grande relevância na vida cotidiana, exercendo influência sobre o humor e o estado de espírito das pessoas, especialmente quando se trata das escolhas de vestuário. São um dos elementos de maior impacto na imagem pessoal e profissional, visto que são condutoras de mensagens e tem o poder de comunicar a nossa identidade, revelar as nossas competências e fazendo transparecer parte de nossa personalidade (Ulrich, 2021).

A coloração pessoal é um estudo que visa identificar as dimensões de cores presentes na pele, como intensidade, profundidade e temperatura, para determinar quais cores harmonizam melhor com o subtom da pele de cada indivíduo, que pode ser classificado como quente, frio ou neutro. Além disso, esse estudo avalia o contraste pessoal e define uma paleta de cores apropriada para roupas, acessórios, coloração do cabelo e maquiagem. As cores têm um impacto significativo na comunicação vi-

sual: certas cores podem minimizar olheiras, marcas de expressão, espinhas e manchas, proporcionando uma aparência saudável e radiante. Em contraste, outras cores podem acentuar imperfeições, dando ao rosto uma aparência mais cansada e apagada (Carvalho, 2019).

A análise de coloração pessoal consiste na identificação das cores que harmonizam melhor com as características físicas de cada pessoa. Essa análise é realizada através de diferentes métodos, sendo o mais popular o método sazonal expandido, que categorizar os indivíduos em estações do ano (primavera, verão, outono e inverno). No entanto, além dessas categorias principais, há subdivisões que levam em consideração as variações de intensidade, temperatura e profundidade das cores, resultando em doze subcategorias (Carvalho, 2019).

No método sazonal expandido, as quatro estações são divididas em três subgrupos, sendo doze cartelas, conforme apresentado na Figura 1. As estações "puras" são caracterizadas principalmente pela temperatura, como primavera quente, verão frio, outono quente e inverno frio, mantendo as quatro estações originais. Além disso, possui oito estações neutras, em que a temperatura não é o fator principal. Nessas cartelas, as características de profundidade e intensidade são mais marcantes. Entre elas estão o verão e primavera claros, inverno e outono escuros, inverno e primavera brilhantes, além de outono e verão suaves (Medeiros, 2022).

Figura 1 - Método Sazonal Expandido.



Fonte: Medeiros (2022).

Por ser um método que analisa os tons e subtons da pele de um indivíduo, tradicionalmente, esse processo é realizado por profissionais que

utilizam amostras de tecidos e observam as reações da pele a diferentes cores (Carvalho, 2019). No entanto, a aplicação dessa técnica de forma presencial apresenta limitações, como a necessidade de deslocamento e a dependência de condições ambientais controladas, como luz natural adequada.

A utilização de tecnologias de Inteligência Artificial (IA) no processo de análise de coloração pessoal eleva a experiência a um novo patamar, oferecendo resultados mais precisos e personalizados (Perfect, 2023). A personalização tem se tornado um diferencial competitivo significativo em diversos setores, incluindo moda e beleza. Estudos indicam que consumidores estão dispostos a pagar mais por produtos e serviços personalizados que atendam às suas necessidades específicas (Fenech; Perkins; Wixcey, 2015).

Nesse contexto, a utilização de tecnologias baseadas em Inteligência Artificial (IA) e Visão Computacional tem ampliado significativamente as possibilidades de automação e personalização de tarefas que anteriormente dependiam exclusivamente da intervenção humana. Essas tecnologias vêm sendo incorporadas em diversas áreas, como saúde, segurança, agricultura, estética e moda, contribuindo para análises mais precisas, econômicas e escaláveis.

A Inteligência Artificial (IA) é uma área da Ciência da computação que diz respeito ao desenvolvimento de sistemas computacionais que realizam tarefas que, se forem feitas de forma tradicional, requerem inteligência humana, como o raciocínio e resolução de problemas (Barbosa; Portes, 2023). Dentre suas subáreas, destaca-se o Aprendizado de Máquina (*Machine Learning*), que permite aos algoritmos extrair conhecimento de grandes volumes de dados e adaptar seu desempenho com base na experiência.

Já a Visão Computacional, uma vertente da IA, dedica-se ao desenvolvimento de técnicas que possibilitam aos computadores “entender” e interpretar imagens ou vídeos da mesma forma que os seres humanos processam informações visuais. Por meio de algoritmos especializados, essas técnicas realizam tarefas como detecção de objetos, segmentação de regiões de interesse, rastreamento, reconhecimento facial, classificação de imagens, entre outras (Milano; Honorato, 2024).

Esses processos envolvem etapas como o pré-processamento das imagens (remoção de ruídos, normalização, redimensionamento), a extração de características relevantes (textura, cor, bordas, formas), e a poste-

rior análise e interpretação desses dados visuais com o auxílio de modelos matemáticos ou estatísticos. Tais abordagens podem ser supervisionadas, quando há rótulos disponíveis para o treinamento, ou não supervisionadas, quando o algoritmo deve identificar padrões por conta própria.

No campo da estética e da consultoria de imagem, essas tecnologias têm sido utilizadas para auxiliar na análise de características faciais, sugestões de cortes de cabelo, simulações de maquiagem e, mais recentemente, na identificação da coloração pessoal. Com a capacidade de analisar tons, subtons e contrastes diretamente a partir de imagens, ferramentas baseadas em IA tornam esse processo mais ágil, objetivo e acessível, rompendo barreiras físicas e oferecendo resultados personalizados com base em critérios técnicos.

Os algoritmos de visão computacional, têm demonstrado alto desempenho na detecção e classificação de imagens, permitindo uma análise precisa dos tons e subtons da pele (Souza, 2023). Essas tecnologias podem não apenas replicar a precisão dos métodos tradicionais, mas também superar suas limitações ao oferecer análises consistentes independentemente das variáveis ambientais.

A utilização de IA para esse propósito também promove a acessibilidade. Indivíduos que não têm acesso fácil a consultores de imagem podem utilizar o aplicativo para obter recomendações de paletas de cores que realcem sua beleza natural. Isso democratiza o acesso a serviços de consultoria de imagem, tornando-os disponíveis para um público mais amplo e diversificado.

Os aplicativos de identificação de coloração pessoal baseados em IA começam com a captura de uma imagem do usuário, geralmente através da câmera de um smartphone. A imagem é processada por algoritmos de visão computacional que detectam e extraem características específicas da pele, como tonalidade, textura e contrastes.

Diante disso, o protótipo busca apresentar como essas ferramentas, de Inteligência Artificial, serão aplicadas na identificação de tons, subtons de pele, contraste e texturas e irão contribuir para uma personalização mais assertiva, garantindo que as recomendações de paletas de cores realcem a beleza natural dos indivíduos.

Esta pesquisa está estruturada em cinco seções, tendo como a primeira seção a introdução, apresentando o contexto da pesquisa, os objetivos gerais e específicos, além da justificativa para o desenvolvimento do estudo, destacando a relevância da aplicação de técnicas de inteligência

artificial na análise de coloração pessoal. A segunda seção é dedicado à revisão de trabalhos correlatos, trazendo um panorama das principais iniciativas relacionadas ao tema, com destaque para o projeto Deep Armocromia, que utiliza aprendizado profundo para classificação de coloração com base em imagens faciais. Na terceira seção, são descritos os materiais e métodos utilizados, detalhando a estrutura do sistema proposto, o processo de segmentação das imagens, a extração das características cromáticas, as técnicas de redução de dimensionalidade e os métodos de clusterização. A quarta seção trata da discussão de resultados, apresentando as visualizações dos agrupamentos gerados e comparando com o trabalho Deep Armocromia. São analisadas as diferenças entre os modos de entrada (Modo Pele e Modo Rosto), além das limitações enfrentadas, como a escassez de bases rotuladas e a baixa adesão na etapa de validação qualitativa. Por fim, a quinta seção que traz a conclusão do estudo, apresentando os principais resultados alcançados, as contribuições da pesquisa e propondo direções para trabalhos futuros, como a ampliação da base de dados, a adoção de modelos supervisionados e melhorias nos mecanismos de validação.

2 TRABALHOS CORRELATOS

Na literatura, alguns estudos exploram a identificação de padrões estéticos e características individuais, como no caso da análise de coloração pessoal. Dentre eles, destaca-se o estudo realizado por Medeiros (2022), em que a pesquisadora abordou conceitos como a teoria das cores, psicologia das cores, e como a coloração pessoal pode melhorar significativamente nossa autoimagem e autoestima quando usadas de maneira adequada. Os resultados mostraram que a maioria das pessoas sentiu mudanças positivas após descobrir suas cores ideais, relatando maior confiança e elogios por parte de outras pessoas. Destacando a importância de entender como as cores podem afetar nossa percepção de nós mesmos e como os outros nos veem. Mostrando como a escolha correta das cores pode realçar nossa beleza natural, nos fazer sentir mais confiantes e como as cores têm o poder de transmitir mensagens e influenciar nossas emoções.

Hong e Kim (2019) discutem o desenvolvimento de um aplicativo móvel voltado para a escolha de cores de roupas que harmonizem com o tom de pele e cabelo dos usuários. A proposta do artigo é apresentar uma ferramenta que facilite a escolha das cores adequadas, com base em características físicas individuais, de maneira eficiente e acessível. Foi

desenvolvido com base no sistema *Personal Color Design System* (PCDS), que significa sistema de design de coloração pessoal, que classifica tons de pele e cabelo em categorias como *Star*, *Sun*, *Moon* e *Sunset*. A partir dessa classificação, o aplicativo utiliza uma tecnologia que permite a identificação automática das melhores combinações de cores para cada usuário, a partir de uma simples foto tirada pelo próprio usuário. Esse processo elimina a necessidade de consultoria profissional, proporcionando uma análise autônoma e personalizada das cores mais adequadas. Destaca-se como o aplicativo pode melhorar o processo de escolha de roupas, em contraste com os métodos convencionais, que eram complexos, demorados e caros. Em suma, o trabalho apresenta uma inovação tecnológica que simplifica o processo de escolha de cores para roupas, tornando-o acessível ao público geral e oferecendo uma alternativa prática e de baixo custo aos métodos convencionais.

O projeto *Deep Armocromia*, desenvolvido pelo laboratório Vision Robotics and Artificial Intelligence (VRAI) da Universidade de Maceata, na Itália, consiste na criação de uma base de dados rotulada de imagens faciais para análise de coloração pessoal segundo a teoria da *Armocromia Flow*. Para isso, foram coletadas imagens anotadas em colaboração com especialistas da área, garantindo a precisão dos rótulos. Na etapa de modelagem, o trabalho aplicou técnicas avançadas de aprendizado profundo, utilizando redes neurais convolucionais (CNNs) para extrair características faciais relevantes e realizar a classificação das diferentes categorias de coloração. Além disso, foram exploradas arquiteturas específicas para melhorar o desempenho na discriminação das classes, considerando variações de iluminação, poses e expressões faciais presentes nas imagens. O conjunto de dados resultante serve como base para a validação dos modelos, sendo disponibilizado para a comunidade científica interessada em desenvolver soluções automatizadas na área de análise de coloração pessoal (Stacchio et al., 2025).

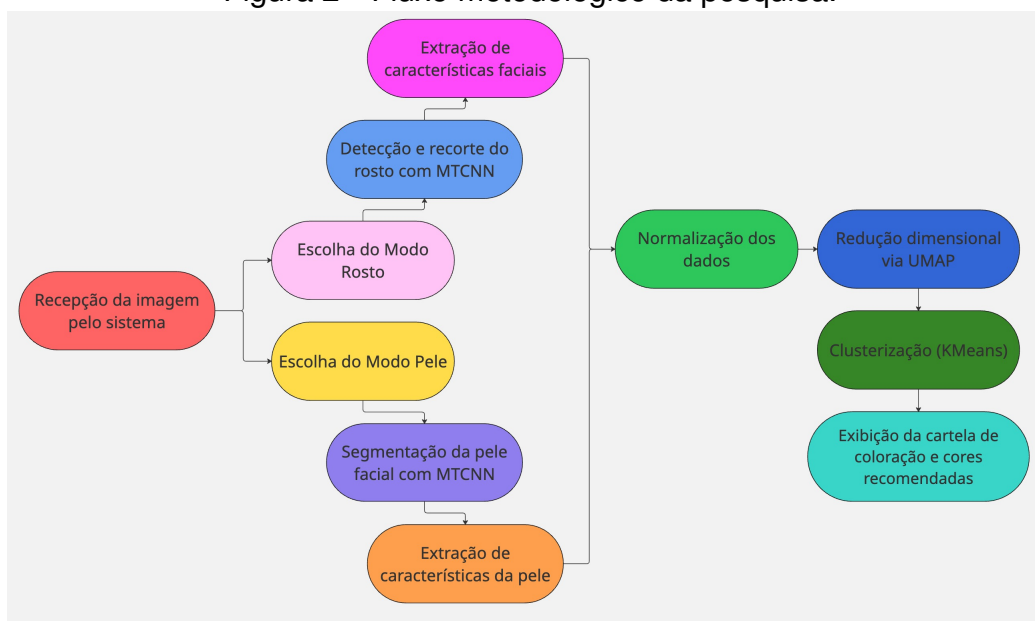
3 MATERIAIS E MÉTODOS

O presente projeto propõe o desenvolvimento de um protótipo de aplicação capaz de realizar a classificação da coloração pessoal de uma imagem facial com base no modelo sazonal expandido. O sistema foi planejado para operar em dois modos de funcionamento distintos: Modo Pele, que considera apenas a análise cromática da pele do rosto, e Modo Rosto, que utiliza a imagem facial completa, incluindo elementos como olhos, boca

e sobrancelhas. Essa dualidade permite comparar abordagens diferentes na análise cromática e avaliar suas implicações na identificação da cartela mais adequada.

A aplicação foi implementada em Python, na versão 3.12.4, utilizando bibliotecas especializadas em visão computacional, aprendizado de máquina e desenvolvimento de interfaces gráficas. Dentre elas, destacam-se ferramentas como OpenCV e MTCNN, empregadas nas etapas de detecção e segmentação facial, bem como scikit-learn e UMAP, utilizadas nos processos de extração de características e agrupamento não supervisionado. A interface do sistema foi construída com o auxílio do Streamlit, que permite a interação dinâmica com o usuário. O funcionamento geral do sistema pode ser visualizado no fluxograma apresentado na Figura 2, que representa o fluxo do sistema ao selecionar o Modo Rosto ou o Modo Pele. Ambas as abordagens seguem uma estrutura semelhante, que compreende etapas como o envio da imagem pelo usuário, pré-processamento, extração de características visuais, agrupamento via algoritmos de aprendizado não supervisionado e a predição da cartela final. Esses fluxos foram desenhados para ilustrar as principais etapas da aplicação, e servem como referência para a explicação técnica mais aprofundada apresentada a seguir.

Figura 2 - Fluxo metodológico da pesquisa.



Fonte: Elaborado pelo autor.

3.1 BASE DE DADOS

Para o desenvolvimento do projeto, foi utilizada a base de dados proveniente do repositório público *Chicago Face Database (CFD)*, realizado por Ma, Correll e Wittenbrink (2025), reconhecido por fornecer imagens de rostos humanos sob condições padronizadas de iluminação, enquadramento e expressão neutra. A base original era composta por um total de 1.440 imagens, sendo 761 do sexo feminino e 679 do sexo masculino. As imagens estavam organizadas em diretórios correspondentes a diferentes grupos étnicos, abrangendo categorias como asiáticos, negros, indianos, latinos, multirraciais e brancos, proporcionando uma diversidade significativa de perfis.

Considerando o foco do trabalho, que se direciona ao público mais frequentemente atendido por consultorias de coloração pessoal, foram selecionadas manualmente apenas as imagens referentes a indivíduos do sexo feminino. Adicionalmente, optou-se por priorizar imagens de mulheres com tons de pele clara e morena, por representarem a maior parte do público-alvo e permitirem uma análise mais consistente no contexto do estudo.

Após a filtragem, a base tinha 460 imagens, sendo descartadas 301 imagens. Diante da limitação de volume, aplicou-se a técnica de data augmentation para duplicar o conjunto de dados. No entanto, por se tratar de uma análise sensível à coloração da pele, descartou-se qualquer transformação que pudesse alterar as características cromáticas da imagem, como brilho, saturação, contraste ou filtros. Além disso, também não foi aplicada rotação nas imagens, uma vez que essa modificação poderia comprometer o desempenho do processo de segmentação facial, dificultando a detecção precisa apenas da região do rosto.

Assim, a única técnica empregada foi o espelhamento horizontal, que preserva integralmente os valores de cor. Com essa estratégia, o número total de imagens aumentou para 920, garantindo maior robustez ao modelo e estabilidade nos processos de treinamento e validação.

Figura 3 - Exemplo da base de dados.



Fonte: Elaborado pelo autor.

3.2 DESENVOLVIMENTO DO PROTÓTIPO DE APLICAÇÃO

A linguagem Python, na versão 3.12.4, foi utilizada como base para o desenvolvimento do sistema por sua ampla adoção, destacando-se especialmente em projetos que envolvem inteligência artificial, visão computacional e ciência de dados. Com o objetivo de tornar o sistema acessível, optou-se por utilizar a biblioteca *Streamlit* na construção da interface gráfica. O *Streamlit* permite o desenvolvimento de aplicações web de forma rápida, intuitiva e interativa.

A interface final construída, permite que o usuário selecione o modo de análise desejado, envie uma imagem facial de forma simples e obtenha, como resultado, o nome da cartela de coloração sugerida, acompanhado da visualização gráfica da paleta correspondente, com blocos de cores organizados de forma clara e objetiva.

O fluxo de processamento da imagem é iniciado com pré-processamento, realizado com o auxílio da biblioteca *OpenCV*, que foi utilizado para preparar as imagens recebidas do usuário, de modo que estivessem adequadas às etapas posteriores de segmentação e extração de características cromáticas.

A seguir, foi realizado a segmentação facial por meio do detector MTCNN (*Multi-task Cascaded Convolutional Networks*), uma abordagem baseada em redes neurais convolucionais que se destaca por sua alta precisão na detecção de faces humanas e seus respectivos pontos-chave. O MTCNN opera em três estágios encadeados de redes convolucionais, sendo capaz de localizar com eficiência estruturas como olhos, sobrancelhas, nariz, boca e contornos faciais, mesmo em condições variadas de iluminação e expressões. Essa etapa é de importância crítica no projeto,

pois fornece as coordenadas necessárias para isolar ou remover regiões específicas do rosto, dependendo do modo de análise selecionado.

Com base nos pontos detectados, o sistema segue dois caminhos distintos de análise, definidos pelo usuário: o Modo Pele e o Modo Rosto. No Modo Pele, o sistema realiza automaticamente a remoção de todos os elementos que não correspondem à pele facial, como olhos, cabelos, sobrancelhas e lábios, preservando exclusivamente as regiões que representam pele pura. Essa segmentação refinada, tem como objetivo capturar com precisão os tons e subtons da pele do indivíduo. Ao focar somente na pele, esse modo permite uma análise mais fiel da temperatura, saturação e profundidade, que são fatores determinantes na definição da coloração pessoal.

Por outro lado, o Modo Rosto adota uma abordagem mais abrangente: em vez de segmentar a pele, a imagem é utilizada em sua totalidade, mantendo todos os elementos visuais da face. Essa estratégia considera, além das características da pele, o contraste do rosto, a presença de sombras naturais e o equilíbrio entre as cores predominantes. Essa análise mais geral permite que o sistema avalie como o rosto, em sua composição cromática completa, interage com diferentes paletas de coloração, levando em conta variáveis como intensidade e profundidade visual, que também influenciam diretamente na escolha da cartela ideal.

A etapa de extração de características também foi estruturada para se adaptar aos dois modos de funcionamento. No Modo Pele, a extração é realizada a partir do espaço de cor LAB, escolhido por sua capacidade de representar de maneira perceptualmente uniforme as variações cromáticas. Diferente do modelo RGB, o espaço LAB é projetado para se aproximar da forma como o olho humano percebe as cores, sendo composto por três canais: L, que representa a luminosidade (do preto ao branco), A, que varia do verde ao vermelho, e B, que varia do azul ao amarelo. Essa separação entre luminosidade e componentes cromáticos permite uma análise mais precisa das nuances de cor, especialmente em tonalidades de pele.

São calculados 27 histogramas de cor, nove para cada canal (L para luminosidade, A para eixo verde-vermelho e B para eixo azul-amarelo). Esses histogramas são empilhados em um vetor de características que oferece uma descrição rica e detalhada das nuances presentes na pele, abrangendo desde tonalidades claras ou profundas até temperaturas quentes ou frias, além de diferentes níveis de saturação.

Já no Modo Rosto, o vetor de características é composto por três grupos de informações complementares. Primeiramente, é calculada a média de cor da pele da imagem, expressa no espaço RGB, o que fornece uma indicação direta da tonalidade predominante. Em seguida, o sistema calcula o contraste facial, definido como o desvio padrão da luminância da imagem, uma métrica útil para avaliar a diferença entre as áreas claras e escuras do rosto. E, por fim, é determinada a cor dominante da imagem, obtida por meio do algoritmo k-means com apenas um centroide, que sintetiza visualmente a cor mais presente e, portanto, mais representativa da composição facial. Essa abordagem busca capturar, de forma objetiva, a combinação de elementos que compõem a aparência cromática do indivíduo.

Os vetores de características obtidos são convertidos para arrays NumPy e, em seguida, normalizados utilizando o *StandardScaler*, uma ferramenta da biblioteca *Scikit-learn*. A normalização dos dados é uma etapa indispensável, pois garante que todas as variáveis tenham média zero e desvio padrão igual a um, o que evita que atributos com escalas maiores dominem a análise e prejudiquem os algoritmos de redução de dimensionalidade e clusterização.

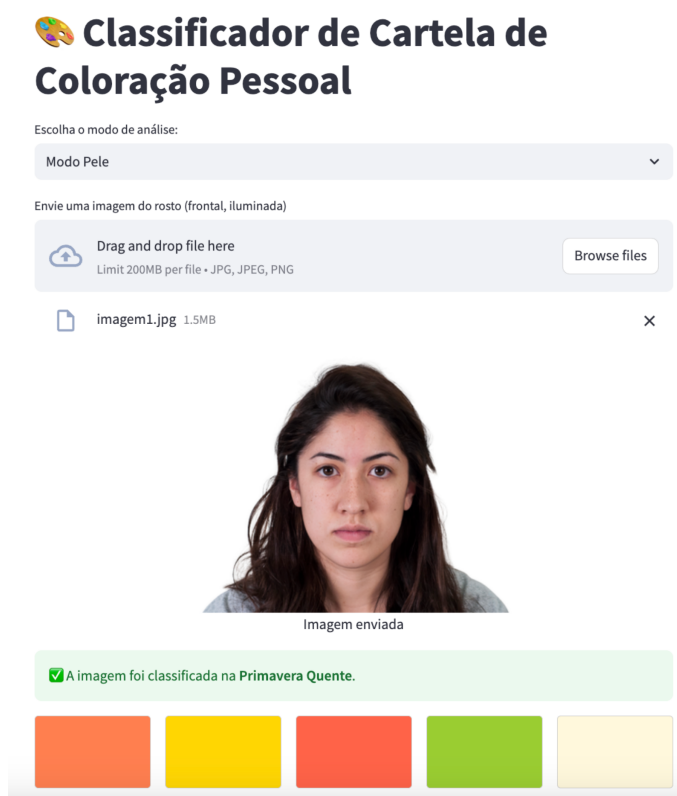
Com os dados preparados, aplica-se a técnica de redução de dimensionalidade UMAP (*Uniform Manifold Approximation and Projection*). A saída do UMAP é então utilizada como entrada para o algoritmo de clusterização não supervisionada k-means, configurado para identificar 12 agrupamentos distintos, cada um representando uma das cartelas do método sazonal expandido.

As cartelas utilizadas no sistema foram definidas com base em fontes da literatura especializada em coloração pessoal, e compreendem as seguintes categorias: Primavera Brilhante, Primavera Clara, Primavera Quente, Verão Claro, Verão Suave, Verão Frio, Outono Suave, Outono Profundo, Outono Quente, Inverno Frio, Inverno Profundo e Inverno Brilhante. Os modelos de normalização, redução de dimensionalidade e clusterização foram treinados separadamente para cada modo (Pele e Rosto), utilizando conjuntos de imagens previamente rotuladas de forma manual com base na cartela real de cada indivíduo. Após o treinamento, os modelos foram salvos com extensão *.pkl*, utilizando a biblioteca *joblib*, e armazenados na pasta modelos-salvos, garantindo sua reutilização durante a execução da aplicação.

Por fim, a interface desenvolvida com *Streamlit* oferece uma ex-

períencia fluida e intuitiva. Conforme mostrado na Figura 4, ao selecionar o modo desejado e carregar uma imagem facial, o usuário recebe, em poucos segundos, o nome da cartela mais compatível com seu perfil cromático, além de uma representação gráfica de sua paleta, com 5 blocos de cores. Essa visualização permite que o usuário compreenda de forma prática e objetiva como as cores daquela cartela se relacionam com seu rosto, promovendo uma aplicação concreta dos princípios de análise cromática pessoal.

Figura 4 - Exemplo do protótipo.



Fonte: Elaborado pelo autor.

3.3 TREINAMENTO E TESTES

Na fase de validação do sistema, foi realizada uma avaliação qualitativa fundamentada no conhecimento técnico da área de coloração pessoal, com o intuito de verificar a acurácia das cartelas de coloração atribuídas pelo protótipo às imagens analisadas. Complementarmente, foi aplicado um questionário³ direcionado a um grupo de seis especialistas em coloração pessoal, a fim de obter um parecer técnico externo e fundamentado acerca das classificações geradas pela aplicação.

³<https://forms.gle/m5gPN9Yt9uNCVKgt9>

Dentre as profissionais contactadas, quatro responderam ao contato. Uma delas negou o preenchimento do questionário, alegando não acreditar na eficácia de análises baseadas exclusivamente em imagens, embora tenha manifestado confiança caso a análise fosse realizada por meio de inteligência artificial. As demais não forneceram retorno, restringindo a amostra de feedbacks disponíveis para análise.

No formulário, foram avaliadas 25 imagens, cujas cartelas foram indicadas pelas especialistas por meio do questionário. Posteriormente, procedeu-se à comparação entre as respostas dadas pelas profissionais e aquelas sugeridas com base nos agrupamentos gerados automaticamente pelo sistema, por meio da clusterização dos vetores de características extraídas das imagens. É importante destacar que o algoritmo de clusterização não realiza uma rotulagem automática com nomes de cartelas, mas sim a separação das imagens em 12 grupos distintos, correspondentes aos doze clusters definidos.

Com base nesses agrupamentos e no conhecimento prévio das especialistas, foram sugeridas associações entre os clusters e as 12 cartelas do método sazonal expandido. No entanto, devido ao número reduzido de respostas completas, visto que apenas três especialistas forneceram feedback integral, essa etapa enfrentou limitações significativas, dificultando uma validação objetiva e definitiva da correspondência entre os grupos formados e as cartelas de coloração pessoal.

Essa comparação possibilitou verificar a concordância entre as classificações humanas e as produzidas pelo modelo, permitindo validar a consistência dos resultados obtidos. Ainda que o número reduzido de respostas limite a generalização dos achados, essa etapa contribuiu para a identificação de tendências e inconsistências, além de destacar potenciais melhorias relativas à qualidade do conjunto de imagens e à diversidade dos perfis faciais analisados.

4 DISCUSSÃO E RESULTADOS

Após a realização dos testes, os resultados obtidos foram organizados conforme os dois modos de análise disponíveis no sistema: Modo Pele e Modo Rosto. Cada modo utiliza diferentes técnicas de extração e clusterização, e portanto seus resultados são apresentados separadamente a seguir.

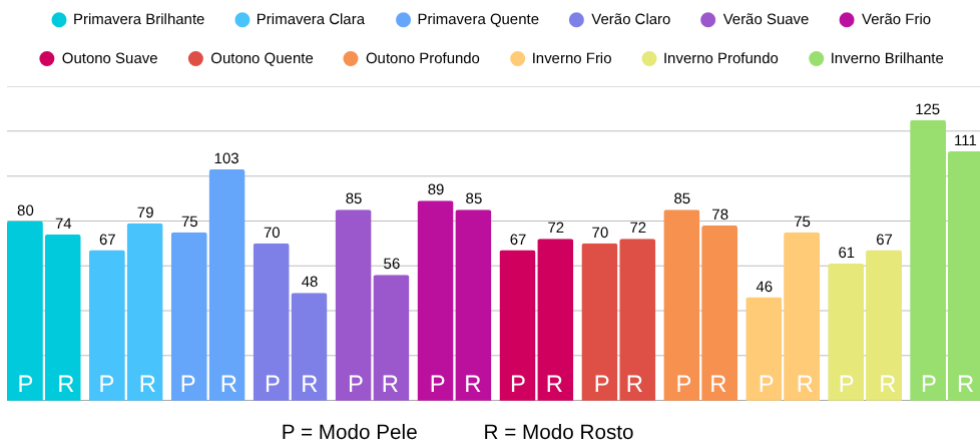
No Modo Pele, foram processadas 920 imagens, nas quais a segmentação removeu olhos, boca, cabelo e demais elementos, preser-

vando apenas as áreas de pele facial. A extração de características foi realizada por meio de histogramas no espaço LAB, com posterior redução dimensional por UMAP e clusterização com k-means em 12 grupos.

Já no Modo Rosto, as mesmas imagens foram processadas mantendo todos os elementos faciais, com extração de características baseadas em média de cor da pele, contraste e cor dominante. A redução dimensional e clusterização seguiram o mesmo procedimento do Modo Pele.

Conforme apresentado na Figura 5, a distribuição das imagens pelas cartelas sugeridas foi:

Figura 5 - Resultados das imagens.



Fonte: Elaborado pelo autor.

4.1 VISUALIZAÇÃO DOS CLUSTERS

Os gráficos da Figura 6 mostram uma visão simplificada das características das imagens. Cada ponto representa uma imagem, e a posição dos pontos indica o quanto as imagens são parecidas em relação às cores e tons analisados.

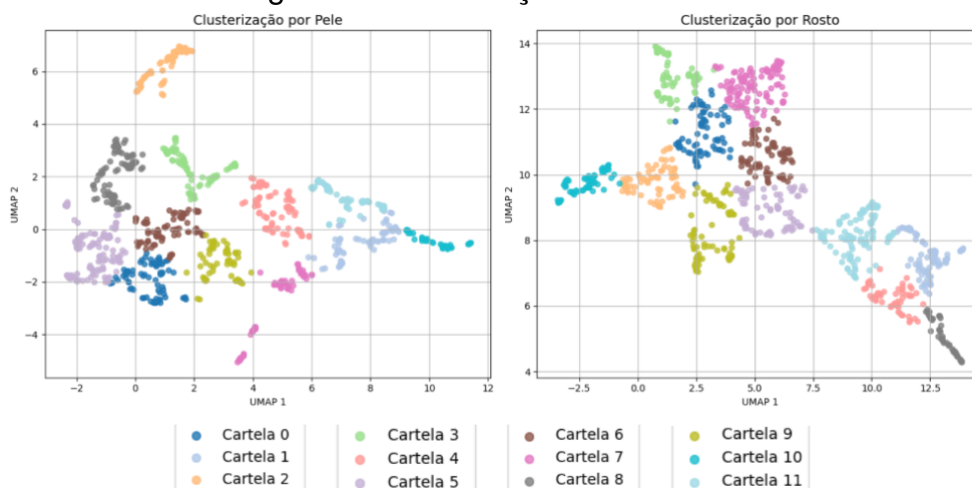
As áreas coloridas ou agrupamentos mostram os clusters formados pelo algoritmo k-means, que separa as imagens em 12 grupos, correspondentes às cartelas de coloração pessoal. Quanto mais próximos os pontos estiverem, mais semelhantes são as características dessas imagens.

Ao observar os gráficos, pode-se ver que as imagens que pertencem à mesma cartela ficam agrupadas, o que indica que o sistema conseguiu diferenciar bem as cartelas baseando-se nas cores da pele ou do rosto, conforme o modo selecionado.

Diferenças na forma como os grupos aparecem em cada gráfico refletem as variações entre os dois modos de análise (Pele e Rosto), que

serão exploradas mais adiante.

Figura 6 - Visualização dos clusters.



Fonte: Elaborado pelo autor.

Para avaliar se os resultados do sistema faziam sentido, foi realizada uma comparação entre as cartelas indicadas pelas especialistas no formulário e os grupos formados automaticamente pelo modelo. Das 25 imagens analisadas, foi verificado se cada uma havia sido alocada em um grupo compatível com a cartela apontada pelas profissionais. Em alguns casos, no entanto, houve divergência nas respostas. Conforme apêndice A, algumas imagens receberam três cartelas diferentes, o que evidenciou a falta de consenso entre as avaliadoras. Por conta disso, em vez de simplesmente descartar os dados, foram considerados diferentes critérios de validação para compreender melhor o desempenho do sistema. Assim, a comparação foi feita com base em cenários variados, levando em conta o grau de concordância entre as respostas.

A Tabela 1 apresenta um resumo dos resultados obtidos nos diferentes cenários de validação aplicados às imagens testadas no sistema. Observa-se que, considerando todas as imagens avaliadas, sem qualquer tipo de filtragem, o percentual médio de acerto foi de 32% no Modo Pele e 34% no Modo Rosto. Quando desconsideradas as imagens com respostas divergentes entre as especialistas (ou seja, aquelas com três respostas diferentes de cartelas), os resultados melhoram levemente, alcançando 35% e 37%, respectivamente. Excluindo-se apenas as imagens que não apresentaram nenhuma correspondência entre as cartelas sugeridas pelo sistema e aquelas indicadas pelas especialistas (casos de 0% de acerto), os percentuais aumentam para 51% no Modo Pele e 49% no

Modo Rosto. No cenário mais rigoroso, no qual foram mantidas apenas as imagens com pelo menos duas respostas coincidentes entre as especialistas e com alguma correspondência com os agrupamentos gerados, o desempenho atinge 57% no Modo Pele e 55% no Modo Rosto.

Tais resultados sugerem que a confiabilidade das validações humanas influencia diretamente na medição de desempenho do sistema, reforçando a importância de uma base de validação mais padronizada e com maior concordância entre os avaliadores.

Tabela 1 - Comparação de desempenho entre os modos de funcionamento

Critério de Validação	Modo Pele	Modo Rosto
Considerando todas as imagens avaliadas	32%	34%
Desconsiderando imagens com 3 respostas diferentes	35%	37%
Desconsiderando imagens com 0% de correspondência	51%	49%
Desconsiderando ambos os casos (3 respostas diferentes e 0% de acerto)	57%	55%

Fonte: Elaborado pelo autor.

Ao comparar os resultados obtidos neste estudo com os apresentados no trabalho *Deep Armocromia*, é possível perceber diferenças importantes tanto na forma como os sistemas foram desenvolvidos quanto nos resultados alcançados. O *Deep Armocromia* utilizou uma abordagem com inteligência artificial supervisionada, treinando modelos avançados, como ResNeXt50 e FaRL, com um banco de dados previamente classificado por especialistas. Dessa forma, o projeto atingiu índices de acerto bastante altos, chegando a 77% e 80%.

Já o presente estudo seguiu um caminho diferente. Em vez de treinar modelos com respostas prontas, foi adotada uma abordagem não supervisionada, que agrupa as imagens com base nas semelhanças naturais de cor observadas na pele das pessoas. Como não havia um grande conjunto de dados rotulado, essa escolha foi mais viável. Os acertos variaram entre 32% e 57%, dependendo do critério adotado na análise.

Apesar de os números serem mais baixos, é importante lembrar que os dois estudos têm propósitos e condições diferentes. O *Deep Armocromia* depende de um volume grande de dados anotados por especialistas

e exige mais recursos para treinamento. Em contrapartida, o presente trabalho propõe uma solução mais leve e simples de entender. Os resultados obtidos mostram que mesmo sem dados rotulados, é possível construir um sistema funcional, principalmente quando há maior concordância entre os avaliadores. Isso indica que a proposta tem potencial para ser aprimorada e ampliada em estudos futuros.

Uma das principais dificuldades enfrentadas neste trabalho foi a inexistência de bases de dados públicas amplas e previamente classificadas segundo as 12 cartelas do método sazonal expandido, o que inviabilizou a aplicação de técnicas supervisionadas. Como alternativa, foi realizado um processo de clusterização e, posteriormente, uma validação qualitativa a partir da opinião de especialistas em coloração pessoal. No entanto, essa validação enfrentou limitações, já que apenas 4 das 6 especialistas convidadas responderam ao questionário, e, dessas, apenas três forneceram feedback completo. Essa limitação no número de respostas restringiu a possibilidade de uma avaliação mais robusta dos agrupamentos gerados.

Essas diferenças metodológicas, de validação e de disponibilidade de dados destacam os desafios presentes na automatização da análise de coloração pessoal, além de apontarem caminhos alternativos para futuras investigações nesse campo, considerando tanto abordagens supervisionadas quanto não supervisionadas.

5 CONCLUSÃO

Este trabalho teve como objetivo o desenvolvimento de um protótipo de aplicação capaz de identificar a coloração pessoal a partir de imagens faciais, utilizando técnicas de inteligência artificial e aprendizado supervisionado e não supervisionado. Para isso, foi proposta uma abordagem baseada na segmentação automática da pele do rosto, extração de características cromáticas relevantes e aplicação de algoritmos de redução de dimensionalidade e clusterização para classificar as imagens em uma das doze cartelas do sistema sazonal expandido. A metodologia foi estruturada em dois modos de entrada, Modo Pele e Modo Rosto, permitindo a comparação entre uma análise focada exclusivamente na tonalidade da pele e outra que considera o rosto completo.

Este trabalho demonstrou que é possível desenvolver uma aplicação funcional e coerente para a análise de coloração pessoal com apoio de inteligência artificial, contribuindo com uma alternativa prática e acessí-

vel para um processo tradicionalmente realizado apenas de forma presencial e subjetiva.

Como sugestão para trabalhos futuros, recomenda-se ampliar a base de imagens utilizadas, incluindo mais fotos avaliadas por especialistas e buscando maior diversidade, especialmente com a presença de peles negras, que ainda são pouco representadas em muitos estudos de coloração pessoal. Além disso, é importante melhorar a etapa de validação dos resultados, envolvendo um número maior de especialistas e utilizando formas mais claras e objetivas de medir o desempenho do sistema, o que pode tornar a avaliação mais confiável.

REFERÊNCIAS

BARBOSA, L. M.; PORTES, L. A. F. **A INTELIGÊNCIA ARTIFICIAL**. Associação Brasileira de Tecnologia Educacional, 2023. v. 236. 16-27 p. Acesso em: 10 abr. 2025. ISSN 0102-5503. Disponível em: <<https://www.abt-br.org.br>>.

CARVALHO, M. **Colorimetria: tudo sobre o estudo da coloração pessoal**. 2019. Acesso em: 10 maio 2025. Disponível em: <<https://vogue.globo.com/moda/noticia/2019/10/colorimetria-tudo-sobre-o-estudo-da-coloracao-pessoal.html>>.

FENECH, C.; PERKINS, B.; WIXCEY, N. **The deloitte consumer review: Made-to-order – the rise of mass personalisation**. 2015, London, United Kingdom. Acesso em: 10 abr. 2025. Disponível em: <<https://www2.deloitte.com/content/dam/Deloitte/global/Documents/Consumer-Business/gx-consumer-review-mass-personalisation.pdf>>.

HONG, H. R.; KIM, Y. I. **A mobile application for personal colour analysis**. Taylor & Francis, 2019. v. 6. 1576828 p. Acesso em: 25 mar. 2025. Disponível em: <<https://doi.org/10.1080/23311975.2019.1576828>>.

MA, D. S.; CORRELL, J.; WITTENBRINK, B. **Chicago Face Database**. 2025. Acesso em 3 abr. 2025. Disponível em: <<https://www.chicagofaces.org/>>.

MEDEIROS, N. N. **A influência da coloração pessoal na autoestima e autoimagem**. Trabalho de Conclusão de Curso (TCC) — Universidade do Extremo Sul Catarinense - UNESC / Serviço Nacional de Aprendizagem Industrial - SENAI, Criciúma, junho 2022.

MILANO, D. de; HONORATO, L. B. **Visão Computacional**. Rua Paschoal Marmo, 1888 - Jardim Nova Itália - Limeira/SP: [s.n.], 2024.

Perfect. **Análise de cores AI: o guia completo 2024**. 2023. Acesso em: 25 abr. 2025. Disponível em: <<https://www.perfectcorp.com/business/blog/general/unveiling-personal-color-analysis-with-ai-tech#:~:>

text=URL%3A%20https%3A%2F%2Fwww.perfectcorp.com%2Fbusiness%2Fblog%2Fgeneral%2Funveiling,100>.

STACCHIO, L. et al. **Deep armocromia: A novel dataset for face seasonal color analysis and classification**. 2025, Springer Nature Switzerland, Cham, p. 352–367. Acesso em: 10 abr. 2025. Disponível em: <https://www.researchgate.net/publication/383463705_Deep_Armocromia_A_Novel_Dataset_for_Face_Seasonal_Color_Analysis_and_Classification>.

ULRICH, L. **O impacto das cores na imagem pessoal e profissional**. Cuaderno del Centro de Estudios en Diseño y Comunicación, 2021, Centro de Estudios en Diseño y Comunicación, Facultad de Diseño y Comunicación, Universidad de Palermo, Buenos Aires, Argentina, n. 97, p. 55–64. ISSN 1668-0227.

APÊNDICE A

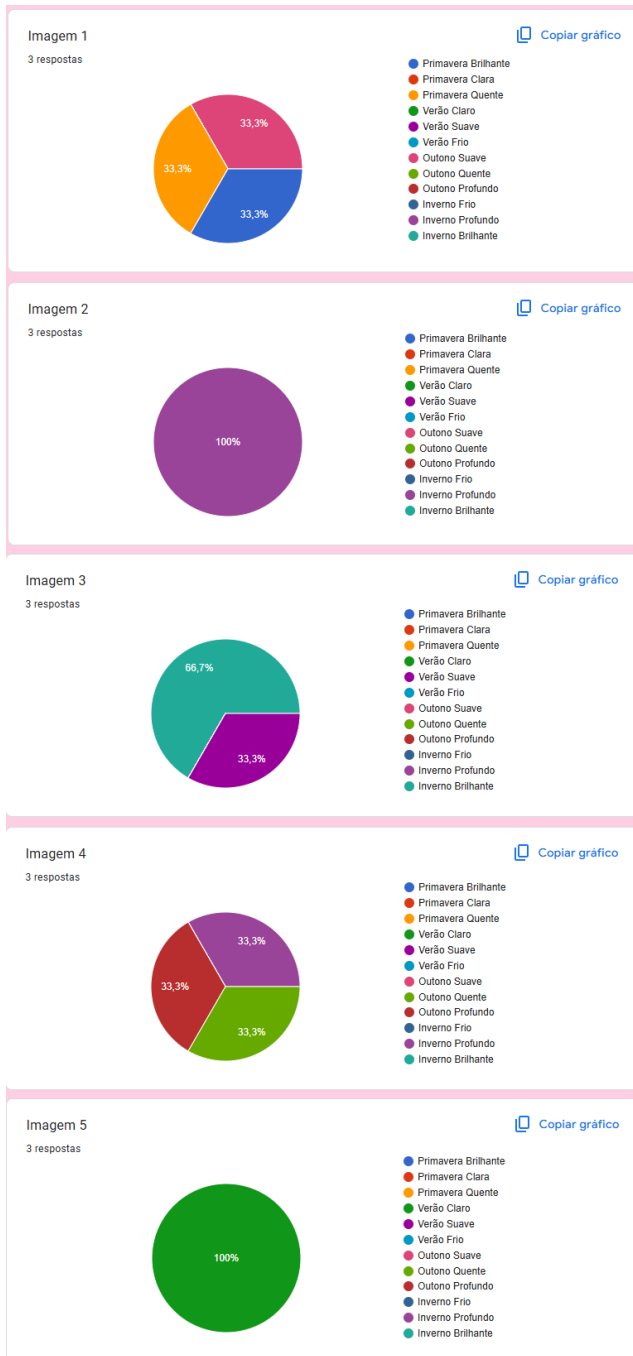



Imagem 6

3 respostas

[Copiar gráfico](#)




- Primavera Brilhante
- Primavera Clara
- Primavera Quente
- Verão Claro
- Verão Suave
- Verão Frio
- Outono Suave
- Outono Quente
- Outono Profundo
- Inverno Frio
- Inverno Profundo
- Inverno Brilhante

Imagem 7

3 respostas

[Copiar gráfico](#)




- Primavera Brilhante
- Primavera Clara
- Primavera Quente
- Verão Claro
- Verão Suave
- Verão Frio
- Outono Suave
- Outono Quente
- Outono Profundo
- Inverno Frio
- Inverno Profundo
- Inverno Brilhante

Imagem 8

3 respostas

[Copiar gráfico](#)




- Primavera Brilhante
- Primavera Clara
- Primavera Quente
- Verão Claro
- Verão Suave
- Verão Frio
- Outono Suave
- Outono Quente
- Outono Profundo
- Inverno Frio
- Inverno Profundo
- Inverno Brilhante

Imagem 9

3 respostas

[Copiar gráfico](#)




- Primavera Brilhante
- Primavera Clara
- Primavera Quente
- Verão Claro
- Verão Suave
- Verão Frio
- Outono Suave
- Outono Quente
- Outono Profundo
- Inverno Frio
- Inverno Profundo
- Inverno Brilhante

Imagem 10

3 respostas

[Copiar gráfico](#)




- Primavera Brilhante
- Primavera Clara
- Primavera Quente
- Verão Claro
- Verão Suave
- Verão Frio
- Outono Suave
- Outono Quente
- Outono Profundo
- Inverno Frio
- Inverno Profundo
- Inverno Brilhante

Imagem 11

3 respostas

[Copiar gráfico](#)




- Primavera Brilhante
- Primavera Clara
- Primavera Quente
- Verão Claro
- Verão Suave
- Verão Frio
- Outono Suave
- Outono Quente
- Outono Profundo
- Inverno Frio
- Inverno Profundo
- Inverno Brilhante

Imagem 12

3 respostas

[Copiar gráfico](#)




- Primavera Brilhante
- Primavera Clara
- Primavera Quente
- Verão Claro
- Verão Suave
- Verão Frio
- Outono Suave
- Outono Quente
- Outono Profundo
- Inverno Frio
- Inverno Profundo
- Inverno Brilhante

Imagem 13

3 respostas

[Copiar gráfico](#)




- Primavera Brilhante
- Primavera Clara
- Primavera Quente
- Verão Claro
- Verão Suave
- Verão Frio
- Outono Suave
- Outono Quente
- Outono Profundo
- Inverno Frio
- Inverno Profundo
- Inverno Brilhante

Imagem 14

3 respostas

[Copiar gráfico](#)




- Primavera Brilhante
- Primavera Clara
- Primavera Quente
- Verão Claro
- Verão Suave
- Verão Frio
- Outono Suave
- Outono Quente
- Outono Profundo
- Inverno Frio
- Inverno Profundo
- Inverno Brilhante

Imagem 15

3 respostas


[Copiar gráfico](#)



- Primavera Brilhante
- Primavera Clara
- Primavera Quente
- Verão Claro
- Verão Suave
- Verão Frio
- Outono Suave
- Outono Quente
- Outono Profundo
- Inverno Frio
- Inverno Profundo
- Inverno Brilhante

Imagem 16

3 respostas




[Copiar gráfico](#)

- Primavera Brilhante
- Primavera Clara
- Primavera Quente
- Verão Claro
- Verão Suave
- Verão Frio
- Outono Suave
- Outono Quente
- Outono Profundo
- Inverno Frio
- Inverno Profundo
- Inverno Brilhante

Imagem 17

3 respostas




[Copiar gráfico](#)

- Primavera Brilhante
- Primavera Clara
- Primavera Quente
- Verão Claro
- Verão Suave
- Verão Frio
- Outono Suave
- Outono Quente
- Outono Profundo
- Inverno Frio
- Inverno Profundo
- Inverno Brilhante

Imagem 18

3 respostas




[Copiar gráfico](#)

- Primavera Brilhante
- Primavera Clara
- Primavera Quente
- Verão Claro
- Verão Suave
- Verão Frio
- Outono Suave
- Outono Quente
- Outono Profundo
- Inverno Frio
- Inverno Profundo
- Inverno Brilhante

Imagem 19

3 respostas




[Copiar gráfico](#)

- Primavera Brilhante
- Primavera Clara
- Primavera Quente
- Verão Claro
- Verão Suave
- Verão Frio
- Outono Suave
- Outono Quente
- Outono Profundo
- Inverno Frio
- Inverno Profundo
- Inverno Brilhante

Imagem 20

3 respostas




[Copiar gráfico](#)

- Primavera Brilhante
- Primavera Clara
- Primavera Quente
- Verão Claro
- Verão Suave
- Verão Frio
- Outono Suave
- Outono Quente
- Outono Profundo
- Inverno Frio
- Inverno Profundo
- Inverno Brilhante

Imagem 21

3 respostas

[Copiar gráfico](#)




- Primavera Brilhante
- Primavera Clara
- Primavera Quente
- Verão Claro
- Verão Suave
- Verão Frio
- Outono Suave
- Outono Quente
- Outono Profundo
- Inverno Frio
- Inverno Profundo
- Inverno Brilhante

Imagem 22

3 respostas

[Copiar gráfico](#)




- Primavera Brilhante
- Primavera Clara
- Primavera Quente
- Verão Claro
- Verão Suave
- Verão Frio
- Outono Suave
- Outono Quente
- Outono Profundo
- Inverno Frio
- Inverno Profundo
- Inverno Brilhante

Imagem 23

3 respostas

[Copiar gráfico](#)




- Primavera Brilhante
- Primavera Clara
- Primavera Quente
- Verão Claro
- Verão Suave
- Verão Frio
- Outono Suave
- Outono Quente
- Outono Profundo
- Inverno Frio
- Inverno Profundo
- Inverno Brilhante

Imagem 24

3 respostas

[Copiar gráfico](#)




- Primavera Brilhante
- Primavera Clara
- Primavera Quente
- Verão Claro
- Verão Suave
- Verão Frio
- Outono Suave
- Outono Quente
- Outono Profundo
- Inverno Frio
- Inverno Profundo
- Inverno Brilhante

Imagem 25

3 respostas

[Copiar gráfico](#)



- Primavera Brilhante
- Primavera Clara
- Primavera Quente
- Verão Claro
- Verão Suave
- Verão Frio
- Outono Suave
- Outono Quente
- Outono Profundo
- Inverno Frio
- Inverno Profundo
- Inverno Brilhante