



UNIVERSIDADE FEDERAL DO ESTADO DO RIO DE JANEIRO
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA

MACHINE LEARNING E A DIVERSIDADE RACIAL BRASILEIRA:
UM ESTUDO SOBRE APLICAÇÕES DE CLASSIFICAÇÃO RACIAL
AUTOMATIZADA EM UM CONTEXTO RACIAL COMPLEXO

Leon de França Nascimento

Orientadores

Ana Cristina Bichara Garcia
Gleison Souza dos Santos


RIO DE JANEIRO, RJ - BRASIL
AGOSTO DE 2023

MACHINE LEARNING E A DIVERSIDADE RACIAL BRASILEIRA: UM ESTUDO
SOBRE APLICAÇÕES DE CLASSIFICAÇÃO RACIAL AUTOMATIZADA EM UM
CONTEXTO RACIAL COMPLEXO


Leon de França Nascimento

DISSERTAÇÃO APRESENTADA COMO REQUISITO PARCIAL PARA
OBTENÇÃO DO TÍTULO DE MESTRE PELO PROGRAMA DE PÓS-
GRADUAÇÃO EM INFORMÁTICA DA UNIVERSIDADE FEDERAL DO ESTADO
DO RIO DE JANEIRO (UNIRIO). APROVADA PELA COMISSÃO
EXAMINADORA ABAIXO ASSINADA

Aprovada por:




Ana Cristina Bichara Garcia, Ph.D. (Orientadora) - UNIRIO



Gleison dos Santos Souza, D.Sc. (Orientador) - UNIRIO



Carla Amor Divino Moreira Delgado, D.Sc. - UFRJ



Carlos Eduardo Ribeiro de Mello, D.Sc. - UNIRIO

RIO DE JANEIRO, RJ - BRASIL
AGOSTO DE 2023

Catálogo informatizada pelo(a) autor(a)

244 de França Nascimento, Leon
Machine Learning e a Diversidade Racial
Brasileira: Um estudo sobre aplicações de
classificação racial automatizada em um contexto
racial complexo / Leon de França Nascimento. -- Rio
de Janeiro, 2023.
153

Orientadora: Ana Cristina Bichara Garcia.
Coorientadora: Gleison Dos Santos Souza.
Dissertação (Mestrado) - Universidade Federal do
Estado do Rio de Janeiro, Programa de Pós-Graduação
em Informática, 2023.

1. Aprendizado de Máquina. 2. Biometria Suave.
3. Social Shaping of Technology. 4. Classificação
Racial. I. Bichara Garcia, Ana Cristina, orient.
II. Dos Santos Souza, Gleison, coorient. III.
Título.

AGRADECIMENTOS

Todo trabalho é uma história e uma travessia, onde a companhia de amigos torna o processo laborioso mais leve e factível frente aos grandes desafios de se realizar uma pesquisa científica. Dedico esta dissertação a todos aqueles que foram pilares fundamentais ao meu redor, guiando-me com sabedoria e generosidade. Cada palavra que agora traço é um tributo aos indivíduos que tornaram esta jornada possível.

Antes de todos, é necessário agradecer àqueles que me fizeram chegar até aqui, Cristina e Gleison, meus estimados orientadores, onde desejo agradecer pela sua paciência incansável e orientação valiosa, que são os alicerces sobre os quais esta dissertação laboriosamente se ergueu. Sua luz orientadora iluminou cada página, tornando esta empreitada acadêmica uma realidade.

À minha querida esposa, Tamiriz: Seu apoio inabalável nos momentos de incerteza e dúvida foi um farol que me guiou com confiança. Sua parceria e compreensão tornaram essa jornada mais significativa e gratificante.

À equipe Firjan, especialmente a Antonio, expresso minha gratidão por permitir a harmonização entre meu trabalho e os estudos de mestrado. Essa oportunidade foi essencial para que eu pudesse trilhar este caminho de crescimento e conhecimento.

Aos membros da minha família, amigos, colegas e a todos os autores que contribuíram para o desenvolvimento desta dissertação, expresso meu sincero agradecimento. Cada nome é uma estrela que ilumina o céu desta epopéia acadêmica, trazendo significado e valor a cada página escrita.

NASCIMENTO, LEON DE FRANÇA, **Machine Learning E A Diversidade Racial Brasileira: Um Estudo Sobre Aplicações De Classificação Racial Automatizada Em Um Contexto Racial Complexo**, UNIRIO, 2023. Dissertação de Mestrado. Programa de Pós-Graduação em Informática, UNIRIO.

RESUMO

A tarefa de classificação racial é uma tarefa complexa, dependente de fatores associados a noções fenóticas de pertencimento racial, assim como associações sociais e culturais aos grupos raciais. O objetivo deste estudo é abordar o desafio da caracterização racial automática usando imagens de rostos de pessoas por meio de aprendizado de máquina, considerando as particularidades do contexto brasileiro.

Atualmente, os modelos de classificação existentes foram desenvolvidos em bancos de rostos internacionais, o que não representa as complexidades da realidade racial brasileira, amplamente diversa e miscigenada. Nossa investigação se concentra em avaliar a adaptabilidade e precisão destes modelos no contexto racial brasileiro, considerando as percepções raciais locais. Além disso, busca identificar as deficiências presentes nos modelos atuais e explorar estratégias para adaptar esses modelos às especificidades da população brasileira, possibilitando uma classificação mais representativa das imagens dos rostos de pessoas brasileiras.

Pretendemos analisar como tais modelos podem ser ajustados para capturar as características e diversidade racial que são peculiares ao Brasil. Nessa perspectiva, propusemos um novo modelo, BRA-RACE, fundamentado na criação de um *ensemble* de classificadores binários, acrescido do local de residência dos indivíduos como fator de ajuste para os resultados de classificação racial. O processo de treinamento e teste foi conduzido utilizando uma base de dados organizada neste trabalho a partir de dados públicos, contendo 137.603 imagens rotuladas, com a autodeclaração racial dos candidatos nas eleições de 2016, 2018, 2020 e 2022. Através do modelo proposto, alcançamos uma melhoria substancial no desempenho do classificador racial em relação à modelos generalistas, chegando ao score F1 de 0,745.

Adicionalmente, elaboramos um experimento de opinião com brasileiros onde contrastamos as percepções de participantes humanos com as saídas dos modelos de classificação racial. Encontramos que o BRA-RACE, embora significativamente diferente dos modelos generalistas, não difere significativamente da percepção feita por pessoas. Assim, ao identificar e abordar as limitações dos modelos existentes e adotar estratégias que incorporam informações geográficas relevantes, nosso estudo apresenta um avanço significativo na capacidade de caracterização racial mais justa no contexto brasileiro. Essa nova abordagem ressalta o compromisso em oferecer soluções que consideram a diversidade única do país e contribuir para um progresso mais equitativo na área de reconhecimento racial.

Palavras Chave: Aprendizado de Máquina, Biometria Suave, Social Shaping of Technology, Classificação Racial

ABSTRACT

The task of racial classification is complex, depending on factors associated with phenotypic notions of racial identification, social and cultural associations with racial groups. The objective of this study was to address the challenge of automatic racial characterization using images of human faces through machine learning, considering the peculiarities of the Brazilian context.

Currently, existing classification models are majorly developed on international face datasets. These datasets do not represent the complexities of the Brazilian races, which is widely diverse and mixed. Our investigation focuses on evaluating the adaptability and accuracy of these models in the Brazilian racial context, considering local racial perceptions. Additionally, it aims to identify shortcomings in current models and explore strategies to adapt these models to the specificities of the Brazilian population, enabling a more representative classification of Brazilian individuals' faces.

We intend to analyze how models can be adjusted to capture the racial characteristics and diversity that are unique to Brazil. In this perspective, we propose a new model, BRA-RACE, based on an ensemble of binary classifiers, with the addition of individuals' place of residence as a factor for adjusting the racial classification results. The training and testing process was conducted using a database organized in this work, containing 137,603 labeled images with the self-declared race of candidates in the 2016, 2018, 2020, and 2022 elections. Through the proposed model, we achieved a substantial improvement in the racial classifier's performance compared to generalist models, reaching an F1 score of 0.745.

Additionally, we conducted an opinion experiment with Brazilians in which we compared the perceptions of human participants with the outputs of the racial classification models. We found that BRA-RACE, although significantly different from generalist models, does not significantly differ from human perception. Thus, by identifying and addressing the limitations of existing models and adopting strategies that incorporate relevant geographic information, our study represents a significant advancement in the ability to achieve fairer racial characterization in the Brazilian context. This new approach underscores the commitment to providing solutions that consider the country's unique diversity and contribute to more equitable progress in the field of racial recognition.

Keywords: Machine Learning, Soft Biometrics, Social Shaping of Technology, Racial Classification

Sumário

1 Introdução	13
1.1 Um pequeno preâmbulo sobre a terminologia utilizada	13
1.2 Motivação	13
1.3 Problema da Pesquisa	14
1.4 Objetivo	16
1.4.1 Objetivo Principal.....	16
1.4.2 Objetivos Secundários	16
1.5 Hipótese	16
1.6 Metodologia de Pesquisa	18
1.7 Escopo	19
1.8 Estrutura da Dissertação	20
2 Fundamentação Teórica.....	22
2.1 Classificação Racial.....	22
2.1.1 Classificações raciais no Brasil	24
2.2 Biometria Suave (Soft Biometrics).....	25
2.3 Classificação Racial usando Imagens.....	27
2.3.1 Que estratégias têm sido utilizadas para a classificação racial?	29
2.3.2 Que raças presentes estão presentes nos estudos?	30
2.3.3 Que fontes de dados são utilizadas para classificação racial?	31
2.3.4 Que tipos de informações faciais são utilizadas?	32
2.3.5 Qual o desempenho destas estratégias?	34
2.4 Modelos de aprendizado profundo utilizados em tarefas de classificação racial	34
2.4.1 Visual Geometry Group Very Deep Convolutional Network (VGG).....	35
2.4.2 Residual Network (Resnet).....	37
2.5 Métricas em Classificação Racial.....	39
3 Dataset Faces da Pindorama: Dataset de faces brasileiras para classificação racial baseada em autodeclaração.....	44
3.1 Confeção do Dataset	44
3.2 Caracterização estatística do dataset.....	47
4 Modelo BRA-RACE: Cristalizando a percepção racial brasileira	52
4.1 Estratégia de melhoria para classificação racial no contexto brasileiro	52
4.2 Definição do modelo	53
5 Experimentos	56
5.1 Cuidados para o treinamento do modelo	56
5.2 Modelos generalistas conseguem classificar as classificações raciais brasileiras? Avaliando nossa linha de base.....	58
5.3 Treinamento do Modelo Multiclasse baseado na arquitetura VGG	63

5.4 Implementação do Modelo BRA-RACE	65
5.4.1 Classificadores OvR	65
5.4.2 Classificadores OvO	67
5.4.3 Agregação de Informações Geográficas e Agregação do Ensemble	69
5.4.4 Autodeclaração e Heteroidentificação: Experimento de pesquisa de opinião ..	74
5.4.5 Resultados do experimento.....	77
5.4.6 O Espelho biométrico	83
6 Discussão.....	86
6.1 Dataset Faces da Pindorama	86
6.2 Avaliação de modelos generalistas para classificação racial brasileira.....	87
6.3 O modelo BRA-RACE como ferramenta dedicada à classificação racial brasileira	88
6.4 O modelo BRA-RACE sob a ótica de SI.....	90
6.5 Limitações e ameaças à validade.....	90
6.6 Trabalhos Relacionados.....	92
7 Conclusão	95
7.1 Contribuição da Pesquisa.....	95
7.2 Trabalhos Futuros	96
8 Referências	97
Anexo 1: Respostas dos participantes do experimento de opinião.....	105

Índice De Figuras

Figura 1: A distribuição das variações de cor de pele das populações indígenas antes da colonização pelos europeus	21
Figura 2: Fluxograma de seleção de artigos da revisão bibliográfica	27
Figura 3: Categorias raciais presentes nos estudos encontrados na revisão.....	28
Figura 4: Informações faciais utilizadas para classificação racial automatizada baseada em imagens....	31
Figura 5: Representação visual das camadas da rede profunda VGG 16.	33
Figura 6: Descrição das camadas da arquitetura ResNet conforme o número de camadas da rede profunda.	36
Figura 7: Exemplo de curvas de distribuição de probabilidade para a distribuição chi-quadrado com diferentes graus de liberdade	41
Figura 8: Distribuição etária dos candidatos presentes no conjunto de dados	45
Figura 9: Distribuição das autodeclarações raciais dos candidatos presentes no conjunto de dados	46
Figura 10: Distribuição das autodeclarações raciais dos candidatos presentes no conjunto de dados após aglutinar as categorias “amarela”, “indígena” e “não informado” como Outros	47
Figura 11: Exemplos de indivíduos presentes no conjunto de dados, representado por categoria de autodeclaração	49
Figura 12: Esquematização do modelo BRA-RACE. O modelo agrega a classificação binária para investigação OvO e OvR das categorias raciais brasileiras, além de agregar as informações geográficas.	51
Figura 13: Adaptação da rede VGG-16 por redimensionamento.	56
Figura 14: Matriz de confusão de classificação para o modelo VGG adaptado disponibilizado pela biblioteca DeepFace.	57
Figura 15: Matriz de confusão de classificação para o modelo ResNet adaptado disponibilizado pela ClarifAI.	58
Figura 16: Distribuição das categorias atribuídas pela implementação da VGG-16 conforme a autodeclaração racial do indivíduo.	59
Figura 17: Distribuição das categorias atribuídas pela implementação da ResNet conforme a autodeclaração racial do indivíduo.	59
Figura 18: Matriz de confusão de classificação para o modelo VGG-16 adaptado e treinado sobre o conjunto de dados Faces da Pindorama.	62
Figura 19: Matriz de confusão de classificação para o classificador binário OvR Brancas vs Outros, baseado em VGG-16 adaptado e treinado sobre o conjunto de dados Faces da Pindorama.	63
Figura 20: Matriz de confusão de classificação para o classificador binário OvR Pretas vs Outros, baseado em VGG-16 adaptado e treinado sobre o conjunto de dados Faces da Pindorama.	64
Figura 21: Matriz de confusão de classificação para o classificador binário OvR Pardas vs Outros, baseado em VGG-16 adaptado e treinado sobre o conjunto de dados Faces da Pindorama.	64
Figura 22: Matriz de confusão de classificação para o classificador binário OvO Preta vs Parda, baseado em VGG-16 adaptado e treinado sobre o conjunto de dados Faces da Pindorama.	65
Figura 23: Matriz de confusão de classificação para o classificador binário OvO Branca vs Parda,	

baseado em VGG-16 adaptado e treinado sobre o conjunto de dados Faces da Pindorama.	66
Figura 24: Matriz de confusão de classificação para o classificador binário OvO Branca vs Preta, baseado em VGG-16 adaptado e treinado sobre o conjunto de dados Faces da Pindorama.	66
Figura 25: Matriz de confusão de classificação para o BRA-RACE, usando um classificador final do tipo SVM, sobre o conjunto de dados Faces da Pindorama.	68
Figura 26: Matriz de confusão de classificação para o BRA-RACE, usando um classificador final Bayesiano, sobre o conjunto de dados Faces da Pindorama.	69
Figura 27: Matriz de confusão de classificação para o BRA-RACE, usando um classificador final do tipo Perceptron Multicamada, sobre o conjunto de dados Faces da Pindorama.	70
Figura 28: Resultados do modelo BRA-RACE MLP após x-scrambling.....	71
Figura 29: Tela inicial do sistema de informação utilizado para coleta dos dados de heteroidentificação pela pesquisa de opinião.	73
Figura 30: Tela de coleta de opinião do sistema de informação utilizado para coleta dos dados de heteroidentificação pela pesquisa de opinião.	74
Figura 31: Matriz de confusão gerada entre as classificações obtidas pela votação da maioria dos participantes e a raça autodeclarada do candidato na amostra utilizada para o experimento de opinião.	76
Figura 32: Matriz de confusão gerada entre as classificações obtidas pelo classificador generalista baseado em VGG (Deepface) e a raça autodeclarada do candidato na amostra utilizada para o experimento de opinião.	77
Figura 33: Matriz de confusão gerada entre as classificações obtidas pela implementação MLP do BRA-RACE e a raça autodeclarada do candidato na amostra utilizada para o experimento de opinião.	78
Figura 34: Tela de exemplo do espelho biométrico de Wouters et al. Extraído de [113]	83
Figura 35: Tela inicial do espelho biométrico desenvolvido sobre o BRA-RACE.	84
Figura 36: Tela de avaliação e feedback das leituras do espelho biométrico desenvolvido sobre o BRA-RACE.	84

Índice De Tabelas

Tabela 1: Perguntas Norteadoras da Revisão Sistemática	25
Tabela 2: Conjuntos de dados encontrados na revisão sistemática	29
Tabela 3: Descrição das camadas da arquitetura VGG-16 conforme descrita por Simonyan e Zisserman.	34
Tabela 4: Exemplo de matriz de confusão	38
Tabela 5: Exemplo de matriz para o teste de McNemar	39
Tabela 6: Valores de chi-quadrado para diferentes níveis de significância estatística (p)	41
Tabela 7: Descrição estatística das faces do conjunto de dados proposto	48
Tabela 8: Cobertura das categorias avaliadas pelos classificadores binários	52
Tabela 9: Mapeamento das categorias raciais para o experimento	57
Tabela 10: Resultados de classificação para os modelos generalistas	60
Tabela 11: Resultados de classificação para o modelo VGG treinado sobre o conjunto Faces da Pindorama	62
Tabela 12: Resultados de classificação para o modelo BRA-RACE, usando SVM, treinado sobre o conjunto Faces da Pindorama	68
Tabela 13: Resultados de classificação para o modelo BRA-RACE com classificador Bayesiano, treinado sobre o conjunto Faces da Pindorama	69
Tabela 14: Resultados de classificação para o modelo BRA-RACE com classificador MLP, treinado sobre o conjunto Faces da Pindorama	70
Tabela 15: Tabela de McNemar para comparação entre os resultados de classificação do modelo generalista baseado em VGG (Deepface) e ResNet (Clarifai)	71
Tabela 16: Tabela de McNemar para comparação entre os resultados de classificação do modelo BRA-RACE e o classificador generalista baseado em VGG (Deepface).	72
Tabela 17: Tabela de McNemar para comparação entre os resultados de classificação do modelo BRA-RACE e o classificador generalista baseado em VGG (Deepface).	73
Tabela 18: Tabela de McNemar para comparação entre os resultados de classificação do modelo BRA-RACE e o classificador generalista baseado em VGG (Deepface) na amostra selecionada para o experimento de opinião... ..	77
Tabela 19: Tabela de McNemar para comparação entre os resultados de classificação do modelo BRA-RACE e a heteroidentificação obtida pela votação da maioria na amostra selecionada para o experimento de opinião.	78
Tabela 20: Distribuição da heteroidentificação de indivíduos conforme a avaliação do entrevistador do IBGE conforme autodeclaração. Adaptado de IBGE, Características Étnico-Raciais da População, 2008	79
Tabela 21: Distribuição da heteroidentificação de indivíduos conforme a avaliação do entrevistador do IBGE conforme autodeclaração, após agregação das categorias não oficiais.	80

Tabela 22: Distribuição da heteroidentificação de indivíduos conforme a avaliação do entrevistador do IBGE conforme autodeclaração, após agregação das categorias não oficiais.	81
---	----

1 Introdução

1.1 Um pequeno preâmbulo sobre a terminologia utilizada

Embora na literatura se encontre relatos da tarefa de classificar pessoas conforme suas características raciais como “classificação de etnia” ou “classificação de raça”, este trabalho optou por utilizar o termo “classificação de raça”.

Esta escolha se dá pela compreensão do conceito de raça utilizado pelo IBGE, que como será visto mais adiante no trabalho, é central na escolha das categorias avaliadas. Mas também se dá pela ênfase no caráter fenotípico em contraste com o caráter cultural do termo etnia. O IBGE define raça como uma classificação baseada em características físicas, como cor da pele, formato dos olhos e textura do cabelo, enquanto etnia se refere a um conjunto de características culturais, históricas e linguísticas compartilhadas por um grupo de pessoas [1,2,3].

Assim, ao se abordar questões de classificação racial, nesta dissertação será utilizado o termo "raça" para refletir especificamente sobre as diferenças fenotípicas e os impactos sociais relacionados, levando em consideração a perspectiva adotada pelo IBGE e a distinção entre os conceitos de raça e etnia.

1.2 Motivação

A classificação racial é um fenômeno complexo que tem uma longa história. Ao longo dos séculos, as sociedades humanas desenvolveram várias formas de categorizar as pessoas com base em características físicas e traços hereditários, como cor da pele, formato dos olhos e textura do cabelo. A categorização racial moderna tem suas raízes no século XVIII, quando os europeus começaram a desenvolver teorias científicas e pseudocientíficas para justificar a opressão e a discriminação com base na raça [4] No entanto, é importante reconhecer que essas classificações raciais são socialmente construídas e podem variar amplamente entre diferentes regiões e até mesmo períodos de tempo [5, 6].

Além disso, a classificação racial também envolve um importante aspecto subjetivo, conhecido como "efeito de outra raça" (*other-race effect*), que se refere à tendência das pessoas em reconhecer e distinguir rostos de indivíduos de sua própria raça

com mais facilidade do que rostos de indivíduos de outras raças [7]. Esse fenômeno tem importantes implicações em interações sociais nos contextos educacionais, culturais e até mesmo criminais [8, 9, 10].

Portanto, a preocupação com como a classificação racial ocorre é um importante tema de discussão, pois esta avaliação tem sido utilizada como base para apoio a iniciativas em medidas afirmativas que buscam ofertar reparação histórica, como as cotas raciais, sendo um importante tema de debate [11, 12]. Defensores argumentam que essas políticas são necessárias para corrigir desigualdades históricas e promover a inclusão social de grupos racialmente marginalizados. Por outro lado, críticos argumentam que a classificação racial pode ser arbitrária, subjetiva e perpetuar estereótipos raciais [13, 14, 15].

Isto ocorre, pois, a definição de pertencimento racial pode ser desafiadora em um contexto de diversidade étnica e miscigenação como no caso do Brasil. Composições raciais regionais diferentes podem dificultar a definição de pertencimento a determinados grupos raciais, sendo a atribuição destas categorias possivelmente dependente do contexto demográfico e temporal em que a avaliação é realizada [16]. Atualmente, uma das estratégias mais utilizadas é o uso de comitês de heteroidentificação

Considerando a crescente disponibilidade de sistemas de informação baseados em aprendizado de máquina dedicados à classificação racial usando imagens de indivíduos [17], a classificação racial automatizada de imagens pode ser uma poderosa ferramenta de apoio à decisão e justiça social para garantia de acesso a políticas afirmativas baseadas na percepção racial.

No entanto, ainda não existem estudos avaliando se o uso de modelos de aprendizado de máquina é capaz de cristalizar a percepção social racial em contextos complexos como o brasileiro. Adicionalmente, são escassas as avaliações sobre as avaliações sobre as noções de autodeclaração e heteroidentificação frente a percepção automatizada modelos de aprendizado de máquina [18].

1.3 Problema da Pesquisa

Na literatura, a declaração racial se revela como um tópico intrincado que abarca variados elementos, incluindo a coloração da pele do declarante, sua região geográfica, as concepções sociais associadas à identificação racial e o papel social que a declaração racial desempenha [23]. Delineados os contornos dessa complexidade, destacam-se áreas de pesquisa ainda em aberto:

1. Ainda não existem estudos reportando o uso de classificadores raciais automáticos de imagens de rostos de pessoas no contexto brasileiro. Estudos usando categorias generalistas (branco, asiático, indiano, preto, latino ou médio-oriental) são existentes na literatura [24], assim como estudos com populações étnicas específicas [25, 26], mas nenhum estudo brasileiro.
2. Não existem dados na literatura que investiguem se o uso de modelos de classificação racial de faces generalistas é adequado a contextos raciais complexos, como o é o caso do Brasil.
3. É observada na literatura uma importante escassez de conjuntos de dados dedicados para a tarefa de classificação racial baseadas em imagens de rostos [17];
4. Além disso, inexiste na literatura uma exploração da adequação dos modelos de classificação racial generalistas em contextos de complexidade racial, como é o caso do Brasil. A carência de conjuntos de dados específicos voltados para a classificação racial baseada em imagens faciais é patente [17], sendo ainda mais restrita a disponibilidade de conjuntos de dados que sejam abrangentes e balanceados, considerando categorias raciais não empregadas no Brasil [27]
5. Existe somente um único conjunto de dados de imagens de rostos brasileiros. O único conjunto reportado na literatura de pessoas brasileiras, até a data desta dissertação é o *Dataset* FEI, elaborado pelo laboratório FEI [28] que não foi concebido para a tarefa de classificação racial.
6. Decorrente da ausência de dados brasileiros, ainda é desconhecido se modelos de aprendizado de máquina são capazes de captar o fenômeno da declaração racial no Brasil.

Ou seja, embora exista uma quantidade significativa de trabalhos referentes à classificação racial reportados na literatura, a maioria enfatiza a avaliação restrita a contextos raciais mais gerais, considerando as categorias raciais mais amplas e atreladas à visão histórica estabelecida. Outra vertente dos estudos enfatiza avaliações étnico-raciais regionais, como avaliações sobre subpopulações como as subpopulações chinesas, indonésias ou paquistanesas, por exemplo [25,26, 29-35]. Desta forma, a literatura carece de uma avaliação sobre a aplicação de abordagens de aprendizados de máquina à concepção de classificação racial em contextos étnicos complexos, como o caso brasileiro.

1.4 Objetivo

1.4.1 Objetivo Principal

O presente estudo visa avaliar se modelos de aprendizado de máquina treinados em dados raciais gerais são adequados à utilização em contextos raciais complexos, como o caso da classificação racial brasileira, bem como examinar a relação entre a autodeclaração racial e a classificação racial por terceiros na precisão desses modelos.

1.4.2 Objetivos Secundários

Os objetivos secundários deste trabalho se dedicam a apoiar os experimentos necessários para alcançar os objetivos primários e são:

- Mapear o estado da arte em relação à tarefa de classificação racial automatizada por imagens através de uma revisão sistemática da literatura
- Investigar se o uso de modelos de classificação racial generalistas são aplicáveis a realidade racial brasileira
- Estruturar um conjunto de dados dedicado à classificação racial de indivíduos brasileiros conforme a sua autodeclaração
- Apresentar e descrever um novo modelo para classificação racial automatizada de pessoas brasileiras em ambientes computacionais domésticos, denominado BRA-RACE.

1.5 Hipótese

O nosso estudo está estruturado em dois testes de hipótese distintos. O primeiro teste busca avaliar a adaptabilidade do uso de modelos de classificação racial generalistas em relação às categorias raciais brasileiras. Por sua vez, o segundo teste de hipótese busca avaliar a contribuição de se definir abordagens específicas para o contexto racial brasileiro em relação a não as utilizar. A seguir, descrevemos os testes específicos:

Primeiro teste

- Hipótese Nula: Os modelos internacionais existentes de reconhecimento racial exibem **desempenho aceitável** quando avaliados no contexto do Brasil.
- Hipótese Alternativa: Os modelos internacionais existentes de reconhecimento racial **não apresentam um desempenho aceitável** quando submetidos a testes no

contexto do Brasil.

Dessa forma, nossa hipótese nula é que não há diferença entre usar algoritmos treinados em dados globais ou usar modelos próprios para o cenário brasileiro, sendo desnecessário criar sistemas ajustados para a classificação racial no contexto nacional. Nossa hipótese a ser testada se baseia na concepção de que o fenômeno da classificação racial em populações racialmente complexas, como o Brasil, precisa ser especificamente planejado para que algoritmos de aprendizado de máquina possam representar o fenômeno e que, secundariamente, a capacidade de classificação está atrelada ao fornecimento de dados regionalizados aos modelos construídos.

Segundo teste

- Hipótese Nula: O uso de um "*ensemble*" de classificadores binários para cada classe e para a combinação entre elas com um pós-processamento que ajuste a decisão à luz da diversidade geográfica do país, **não resulta** em um aumento significativo no desempenho do classificador e produz resultados satisfatórios.
- Hipótese Alternativa: O uso de um "*ensemble*" de classificadores binários para cada classe e para a combinação entre elas com um pós-processamento que ajuste a decisão à luz da diversidade geográfica do país, **resulta** em um aumento significativo no desempenho do classificador e produz resultados satisfatórios.

Estas hipóteses se fundamentam na teoria da moldagem social da tecnologia (*Social Shaping of Technology*), que argumenta que a tecnologia não é apenas uma força externa que molda a sociedade, mas também é moldada e influenciada pela sociedade em que é desenvolvida e utilizada. Essa abordagem teórica destaca a interação entre fatores sociais, culturais, políticos e econômicos na criação, adoção e uso da tecnologia [19].

Essa teoria enfatiza que a tecnologia não é neutra e inevitável, mas sim um resultado da interação complexa entre fatores sociais e tecnológicos. Ela nos encoraja a considerar cuidadosamente os efeitos sociais e os contextos nos quais a tecnologia é desenvolvida e implementada, a fim de compreender melhor suas implicações e possíveis consequências para a sociedade como um todo [19]. Exemplos deste fenômeno podem ser observados no uso de telefones móveis, aplicações financeiras e até mesmo tecnologias industriais [20-22].

1.6 Metodologia de Pesquisa

A metodologia de pesquisa utilizada neste trabalho envolveu a realização de quatro tarefas cruciais para investigação das hipóteses propostas. Primeiramente, o estudo buscou mapear as estratégias, dados e desempenhos de classificação racial automatizada descritos na literatura corrente através de uma revisão sistemática da literatura. Esta tarefa ensejou entender as peculiaridades e limitações das abordagens atualmente utilizadas pela comunidade científica, a fim de avaliar sua aplicabilidade no contexto brasileiro.

Além da revisão, o estudo teve como meta a organização de um conjunto de dados contendo imagens de pessoas brasileiras com anotação da declaração racial para viabilizar o treinamento de modelos de aprendizado de máquina para a tarefa de classificação racial no contexto brasileiro que denominamos “FACES da Pindorama”. Para isto, utilizou-se imagens e metadados dos conjuntos de dados abertos disponibilizados pelo Tribunal Superior Eleitoral¹. Os conjuntos do TSE contêm informações sobre os candidatos aos pleitos eleitorais dos anos de 2016, 2018, 2020 e 2022.

Dentre as informações do conjunto foram selecionadas a região geográfica do candidato, a raça autodeclarada e o ano da eleição, consideradas relevantes para a análise proposta neste trabalho. Somente foram utilizados candidatos presentes em mais de uma eleição cuja declaração racial manteve-se inalterada. O conjunto elaborado contém mais de 137 mil faces de indivíduos brasileiros, distribuídos por região, raça, idade e gênero.

A partir deste conjunto, o estudo avaliou a adaptabilidade de modelos para classificação racial automatizada usando dois algoritmos de aprendizado de máquina treinados em dados não-brasileiros selecionados. Este experimento se deu através de experimentos de classificação de imagens de pessoas brasileiras após um mapeamento das classes originais dos classificadores generalistas, uma vez que nem todas as classes locais têm uma classe diretamente mapeada para os classificadores generalistas.

A escolha dos modelos avaliados se deu a partir dos achados da revisão sistemática associados à oferta destes modelos como implementações publicamente disponíveis como ferramentas de classificação racial. Estes modelos utilizam arquiteturas de aprendizado profundo, a arquitetura VGG-16 [79] e a arquitetura ResNet-50 [87]. Além desta avaliação, também se investigou como se o treinamento dos modelos generalistas com dados brasileiros melhora os resultados de classificação racial no Brasil.

Além disso, avaliamos se o modelo proposto para classificação racial, BRA-RACE, composto da agregação de um conjunto de classificadores binários com dados

¹https://dadosabertos.tse.jus.br/dataset/?q=candidatos&res_format=JPEG

geográficos é mais adequado à tarefa de classificação racial de pessoas brasileiras. Para isso, repetimos o experimento de classificação utilizando o classificador baseado no modelo BRA-RACE.

Os classificadores binários utilizados no BRA-RACE são baseados em redes profundas usando a arquitetura VGG-16 e foram treinados para capturar as percepções de pertencimento racial baseado na autodeclaração dos usuários, usando estratégias de classificação multiclasse, classificadores do tipo “Um contra Todos” (*One versus Rest*, daqui em diante, OvR) e “Um contra Um” (*One versus One*, daqui em diante, OvO). Esta estratégia visou transformar o modelo de um classificador multiclasse simples para uma estratégia de aprendizado de máquina em *ensemble*, baseando as decisões tomadas pelo classificador em função do contraste entre as categorias raciais.

Finalmente, buscamos avaliar como os classificadores se comparam em relação à heteroidentificação por terceiros. Para isto, ensejamos um experimento de opinião onde comparou-se os resultados obtidos pelo BRA-RACE e do modelo generalista com as avaliações obtidas através da votação da maioria dos respondentes. Esta abordagem permite avaliar a comparação dos classificadores automáticos com a autodeclaração, a classificação por outros indivíduos e, por último, a sua comparação com classificadores raciais treinados em contextos generalistas.

1.7 Escopo

Esta pesquisa limita-se à avaliação da classificação automatizada de raça em função da autodeclaração de indivíduos baseada estritamente na imagem dos seus rostos e metadados relevantes somente ao contexto geográfico da avaliação. Não é escopo deste trabalho avaliar a relação com outros fatores externos como nome, genealogia ou expressão cultural dos indivíduos avaliados.

A construção dos modelos utilizou-se de técnicas de redes neurais profundas já utilizadas para classificação racial em outros contextos, não sendo escopo deste trabalho propor uma nova arquitetura de aprendizado profundo, se não a aplicação ou combinação de técnicas já documentadas.

Finalmente, em função da própria demografia brasileira, grupos étnico-raciais de menor representação, em particular as pessoas de raça indígena e amarela, foram desconsideradas no estudo, pois, somadas, compõem menos de 1% da população brasileira. Desta forma, priorizamos a avaliação dos três grupos majoritários no país: Brancos, Pardos e Pretos.

1.8 Estrutura da Dissertação

A dissertação a seguir está estruturada da seguinte maneira: No Capítulo 2 - “Fundamentação Teórica”, apresentamos a fundamentação teórica do estudo, que estabelece as bases conceituais e teóricas necessárias para a compreensão do trabalho. Nessa seção, exploramos a literatura existente sobre a classificação racial, os debates em torno da identificação racial, a importância das políticas de reparação histórica e as abordagens de aprendizado de máquina aplicadas à análise de dados raciais.

Em seguida, no Capítulo 3 - “*Dataset Faces da Pindorama: Dataset de faces brasileiras para classificação racial baseada em autodeclaração*”, introduzimos o conjunto de dados Faces da Pindorama. Descrevemos sua origem, fonte, metodologia de coleta e amostragem, bem como suas características demográficas, socioeconômicas e raciais. Também discutimos as considerações éticas e de privacidade relacionadas ao uso desses dados e as medidas tomadas para garantir a confidencialidade e a segurança das informações pessoais.

No capítulo 4 - “Modelo BRA-RACE: Cristalizando a percepção racial brasileira”, nos concentramos na modelagem racial brasileira utilizando um modelo denominado BRA-RACE. O modelo é uma abordagem de *ensemble*, agregando informações sobre classificações binárias sobre pertencimento racial nos grupos raciais brasileiros associadas a incorporação de informações geográficas.

No capítulo 5 - “Experimentos”, descrevemos os experimentos realizados para avaliação dos objetivos do estudo. Descrevemos a capacidade de classificação racial usando modelos generalistas e elaboramos um modelo adaptado usando a arquitetura VGG-16 (Very Deep Convolutional Networks) diretamente no conjunto de dados Faces da Pindorama. Em seguida, detalhamos o processo de pré-processamento dos dados, a seleção das variáveis relevantes e a configuração do modelo que implementa o BRA-RACE. Explicamos como o modelo foi treinado, ajustado e validado, levando em consideração as peculiaridades da classificação racial no contexto brasileiro.

Ainda no capítulo 5, exploramos a comparação entre as classificações realizadas pela implementação do BRA-RACE com os resultados de heteroidentificação, ou seja, a comparação entre as saídas do modelo e a opinião de indivíduos reais. Além disso, realizamos comparações com modelos generalistas para avaliar as divergências entre eficácia e especificidade dos modelos de aprendizado de máquina para classificação racial.

No capítulo 6 - “Discussão” , é feita a discussão dos resultados achados, as contribuições deste estudo para a literatura e a comparação com trabalhos relacionados no campo da classificação racial baseada em imagens. Exploramos a significância dos nossos resultados frente aos achados de modelos generalistas, modelos treinados localmente e heteroidentificação.

Por último, no capítulo 7 - “Conclusão” , encerramos este trabalho resgatando as suas contribuições, discutindo como a comunidade científica pode se beneficiar dos dados produzidos neste trabalho, assim como discutimos novas direções de pesquisa viabilizadas pelos nossos achados.

No anexo I - “Dados do experimento de opinião”, disponibilizamos uma tabela contendo as imagens do experimento de opinião, as opiniões fornecidas pelos participantes e as leituras dadas pelos modelos de aprendizado de máquina utilizados neste trabalho.

2 Fundamentação Teórica

Neste capítulo, abordaremos de forma sucinta alguns importantes aspectos relacionados à classificação racial. Iniciaremos com um breve panorama histórico e definições fundamentais. Em seguida, atenção é dada para as classificações raciais específicas que emergiram no contexto brasileiro. Também será discutida a interseção entre Biometria Suave e classificação racial, analisando seu impacto e implicações. Além disso, uma revisão dos métodos de Aprendizado de Máquina aplicados à classificação racial é descrita e, por fim, forneceremos uma descrição objetiva das arquiteturas das redes VGG-16 e ResNet, aprofundando nosso entendimento sobre essas duas redes profundas de interesse para este estudo.

2.1 Classificação Racial

Hall [36] avalia que as noções de raça são construídas e transformadas através de processos históricos e sociais, muitas vezes ligados à colonização e ao racismo estrutural. Decorrente deste fato, as facetas sociais e tecnológicas envolvidas com a classificação racial tem uma longa história marcada por diferentes perspectivas e critérios ao longo do tempo.

Inicialmente, é importante destacar que a integração cultural desempenhou um papel importante na classificação racial ao longo da história das sociedades. Banton [37] argumenta que a mistura de diferentes culturas e povos em períodos de colonização e expansão frequentemente resultou em hierarquias raciais e classificações baseadas em supostas diferenças físicas e culturais da natureza do encontro entre as civilizações. Consequentemente, essas classificações refletem as visões dominantes e as relações de poder estabelecidas entre os colonizadores e as populações colonizadas.

Especialmente no contexto ibero-americano, a colonização desempenhou um papel significativo na classificação racial, pois foi acompanhada pela imposição de sistemas de hierarquia racial. A figura 1 exibe a característica da coloração de pele média para as populações nativas anteriores à colonização europeia. Em um trabalho sobre o papel da colonização no processo de classificação racial Stoler [39] descreve que o poder colonial e o controle racial foram estabelecidos através da classificação e diferenciação das populações colonizadas pelos europeus. Esses sistemas classificatórios reforçam a

dominação, a exploração e a opressão, moldando as relações sociais e a estrutura de poder nas sociedades coloniais.




Figura 1: A distribuição das variações de cor de pele das populações indígenas antes da colonização pelos europeus. Extraído de *Encyclopedia Britannica* [38]

Uma sistematização desta classificação racial não existiu, no entanto até Johann Friedrich Blumenbach, naturalista do século XVIII, propôr uma classificação racial em seu trabalho "Sobre a variedade das formas humanas" (1775), onde cinco categorias raciais foram definidas: Caucasiano (branco), Mongoliano (amarelo), Malaio (marrom), Etíope (negro) e Americano (vermelho). O embasamento para a construção destas categorias era pautado principalmente em características físicas, como cor da pele, formato do crânio e características faciais e a percepção da superioridade da categoria caucasiana é tema de discussões associadas a erros de tradução do trabalho original [40, 41].

A classificação racial na história foi caracterizada por mudanças e continuidades, revelando as complexidades e dinâmicas das relações raciais. Para Hirschfeld [42], a classificação racial é um processo dinâmico, influenciado por fatores socioculturais, políticos e econômicos. Portanto, a compreensão da história da classificação racial nos permite questionar e desafiar as ideias pré-concebidas sobre raça, reconhecendo a importância de abordagens mais inclusivas e igualitárias.

Atualmente, entendemos que as categorias raciais são socialmente construídas e não têm base científica. As abordagens contemporâneas reconhecem que a raça é um conceito complexo e multifacetado, influenciado por fatores sociais, culturais e

históricos. As categorias raciais atuais geralmente reconhecem a importância da ancestralidade, identidade étnica e autodeclaração. Essas categorias são mais fluidas e reconhecem a diversidade dentro de cada grupo racial, além de enfatizarem a importância do contexto sociocultural na compreensão das identidades raciais [23, 36, 42].

2.1.1 Classificações raciais no Brasil

O processo de classificação racial no Brasil é marcado pela diversidade étnica e pelo legado da colonização, escravidão e imigração. Com a chegada dos portugueses, a miscigenação entre europeus e as populações nativas resultou na formação do grupo racial mameluco [44]. Não logrando sucesso em escravizar a população nativa, a escravidão africana pelos portugueses desempenhou um papel central na história racial do Brasil, com milhões de africanos foram trazidos forçadamente para o país, estabelecendo a formação da população negra no país [45].

Esta diáspora africana resultou em uma grande diversidade étnica dentro deste novo grupo racial brasileiro, que abarca diferentes origens, culturas e tradições [46]. Aos mestiços de escravos negros e colonizadores, denominavam-se mulatos. Além desta denominação mulatos, outra denominação importante são os cafuzos, que são mestiços oriundos de negros e indígenas. Hoje, estas três categorias “mestiças” compõem a população parda do país, que representa aproximadamente 40% da população brasileira [47]

Finalmente, nos séculos XIX e XX, a imigração europeia também teve um impacto significativo na composição racial do Brasil. Milhões de europeus, principalmente italianos e portugueses, migraram para o país em busca de oportunidades [48]. Essa imigração contribuiu para a formação de comunidades brancas e a diversificação étnica, trazendo novos elementos culturais e influências para a sociedade brasileira [49].

Com isso, a população brasileira é composta, entre o fim do século XIX e XX, por indivíduos considerados Brancos, Mestiços (Cafuzos, Mulatos e Mamelucos) e Negros. Em 1872, durante o Império foi realizado o primeiro censo no país, que teve como objetivo principal coletar informações demográficas e econômicas da população brasileira, visando subsidiar políticas públicas e o planejamento do país. Somente em 1920, a coleta de informações sobre a cor ou raça da população foi tornada campo obrigatório, o que refletia uma preocupação em medir a diversidade étnica do país. A partir do censo de 1940, as pesquisas censitárias foram se aprimorando e abrangendo cada

vez mais aspectos da sociedade, incluindo dados educacionais, migração, renda e condições de habitação [50].

Apesar de desde o censo de 1872, o levantamento da cor ou raça da população ter sido uma categoria de classificação utilizada, a forma como essas informações foram coletadas e interpretadas ao longo do tempo reflete as tensões e as transformações nas concepções de raça e identidade racial no Brasil. Durante muitos anos, os censos brasileiros adotaram uma classificação de cor ou raça que refletia uma visão binária, dividindo a população entre brancos e não brancos. Essa abordagem simplificada ignorava a complexidade da diversidade racial e étnica do país, contribuindo para a invisibilização de grupos como indígenas e asiáticos [51, 52].

Atualmente, o Instituto Brasileiro de Geografia e Estatística utiliza um sistema de classificação racial que abrange cinco categorias: branca, preta, parda, amarela e indígena. Essas categorias são utilizadas para coletar informações sobre a composição étnico-racial da população brasileira e auxiliar na análise de desigualdades sociais e econômicas, bem como em políticas públicas voltadas para grupos específicos [1,2,3].

No entanto, ainda persistem desafios na abordagem das questões de pertencimento racial nos censos. A autodeclaração é padrão ouro para questões de declaração racial, uma vez que o pertencimento racial é multifacetado e não se limita à cor da pele, sendo usado como principal parâmetro para disseminação de declaração racial de acordo com a Declaração de Durban [53]. Porém, críticos avaliam que este critério de classificação enfrenta limitações justamente pela identidade racial ser uma construção social e subjetiva, influenciada por fatores históricos, culturais e sociais, dificultando a implementação de políticas públicas pautadas nestes atributos [54].

2.2 Biometria Suave (*Soft Biometrics*)

A biometria suave, também conhecida como "soft biometrics" em inglês, refere-se a área de estudo que avalia características físicas, comportamentais ou socioeconômicas que possam ser utilizadas para auxiliar na identificação e autenticação de seres humanos, usando informações menos específicas que biométricas tradicionais, como as impressões digitais. Características biométricas suaves tem como exemplo informações como idade, gênero, altura, cor do cabelo, entre outras [55].

Ou seja, ao contrário das características biométricas tradicionais, que possuem um alto grau de singularidade e são utilizadas para fins de segurança e controle de acesso, às características suaves são consideradas menos invasivas, sendo mais aceitas em relação à

preservação da privacidade, uma vez que não são identificadores biométricos exclusivos. O caso de uso destas informações são cenários onde uma caracterização é necessária, mas a obtenção de dados biométricos tradicionais pode ser difícil, invasiva ou indesejada [56].

Assim, a biometria suave reduz espaços de busca e auxilia em consultas (*queries*) no contexto de sistemas de informação, uma vez que estas características adicionais permitem uma busca mais precisa. Em sistemas de reconhecimento facial, a utilização de características suaves, como a cor do cabelo ou o estilo de barba, pode ajudar a restringir o conjunto de possíveis correspondências e melhorar a eficiência na busca por indivíduos em um banco de dados de imagens [57].

Além disso, a biometria suave pode ser usada para aprimorar a usabilidade e a personalização de sistemas. Por exemplo, em sistemas de reconhecimento de voz, a análise de características suaves, como a aparência de idade e detecção do gênero do usuário, pode ajudar a adaptar o sistema às preferências e características individuais dos usuários [58]. Essas informações adicionais permitem uma interação mais natural e personalizada, melhorando a experiência do usuário [59].

Outro uso similar é visto em aplicações de marketing personalizado, onde através da análise das características suaves dos consumidores, como idade, gênero e preferências de compra, um sistema pode segmentar e direcionar campanhas publicitárias de forma mais efetiva [60]. Isso permite uma abordagem mais direcionada, oferecendo produtos e serviços que estejam mais alinhados com as preferências individuais dos consumidores.

Embora a biometria suave apresente benefícios em termos de privacidade e oportunidades de melhoria da experiência de usuário, alguns desafios precisam ser considerados [61]: A coleta e o processamento de dados relacionados às características suaves exigem maior cuidado para garantia da privacidade e na conformidade com as regulamentações de proteção de dados. Além disso, a acurácia e a confiabilidade dessas características podem variar dependendo da qualidade dos dados coletados e da forma como são utilizadas [61,62, 63].

Sendo uma especialização deste campo, a classificação racial com base em biometria suave refere-se à utilização destas mesmas características físicas, comportamentais ou socioeconômicas para inferir a raça ou a etnia de uma pessoa. Neste caso, as características biométricas tradicionais podem não ser indicadores de raça, e características suaves podem ser utilizadas como proxies ou indicadores indiretos para inferir a raça de um indivíduo [56, 61].

E em particular, a classificação racial por meio de biometria suave apresenta desafios significativos em relação à noção de que: a) raça é uma construção social complexa, e; b) a definição e a categorização racial podem variar culturalmente e ao longo do tempo. Além disso, a categorização racial é um tema sensível, que se feita sem cautela pode propagar estereótipos e discriminação. Portanto, é essencial que qualquer uso da classificação racial com base em biometria suave seja guiado por princípios éticos, respeitando a privacidade, a dignidade e os direitos fundamentais dos indivíduos.

2.3 Classificação Racial usando Imagens

Realizamos uma Revisão Sistemática da Literatura (RSL) [17] considerando as diretrizes de Page et al [64]. Utilizamos o modelo PICOC (Population, Intervention, Comparison, Outcome and Context) para auxiliar na construção da string de busca. Definimos a População como 'Algoritmos de Classificação Racial', a Intervenção como 'Uso de imagens faciais', a Comparação como 'Tipo de algoritmo utilizado, Tipo de dado utilizado, Fonte de dados utilizada', o Resultado como 'Acurácia e Erros' e o Contexto como 'Aplicações de Biometria Suaves'.

A partir desses elementos, derivamos duas questões de pesquisa (QP) colocadas em duas categorias com base no foco, disponíveis em maior detalhe na tabela 1:

- (i) as estratégias utilizadas, o tipo de classificação realizado e seus resultados, que denominamos “Questões Centradas em Método”; e
- (ii) o tipo de dado utilizado, a fonte do dado e a disponibilidade do dado utilizado, que denominamos “Questões Centradas em Dados”.

Tabela 1: Perguntas Norteadoras da Revisão Sistemática

Grupo de Questões	Questões de Pesquisa
Questões centradas no método	➤ Quais são as técnicas em uso para classificação racial a partir de imagens? ➤ Qual é o desempenho de classificação destes modelos e que métricas têm sido utilizadas?
Questões centradas nos dados	➤ Que raças têm sido classificadas na literatura? ➤ Que tipo de dados faciais tem sido utilizados para classificação racial? ➤ Quais são os conjuntos de dados em uso para treinamento destes modelos?

A construção do termo de busca envolveu o ajuste das palavras-chave com base nos termos obtidos a partir do modelo PICOC descrito traduzidos para a língua inglesa. Durante os testes, observamos um número considerável de estudos relacionados à "*data race*", o que não está relacionado ao tema deste estudo. Como o termo "*race*" pode significar tanto uma competição baseada em velocidade quanto um grupo que compartilha características fenotípicas, nossas consultas removeram o termo "*race detection*". Artigos com títulos como "*Efficient Parallel Determinacy Race Detection for Structured Futures*", ou "*Understanding and Evaluating Dynamic Race Detection with Go*" foram captados com o termo de busca inicial, e não se referem ao tema de interesse do estudo. Assim, o termo de busca final utilizada foi:

(RACE OR ETHNICITY OR RACIAL) AND
(CLASSIFICATION OR DETECTION OR IDENTIFICATION OR RECOGNITION) AND
(FACE OR FACIAL)
NOT "RACE DETECTION"

Utilizamos as seguintes fontes de dados para consultar e buscar artigos: ACM Digital Library, IEEE eXplore, Google Scholar, Scopus e Science Direct. Aplicamos a string de busca nos campos de título, resumo e palavras-chave. Considerando que a revisão mais recente publicada sobre o assunto utilizou artigos publicados até 2018 [65], optamos por definir o período de estudo a partir dessa data para identificar artigos que apresentam os desenvolvimentos atuais no campo desde a última revisão. Devido a isso, incluímos em nossa seleção de artigos aqueles que atendiam aos seguintes critérios:

- O estudo especifica o algoritmo utilizado;
- O objetivo principal do estudo é a classificação/detecção/identificação de raça por meio de aprendizado de máquina;
- O estudo utiliza apenas dados de imagens faciais e;
- O estudo foi escrito nos últimos cinco anos.

Em seguida, foram removidos da seleção de artigos aqueles que atendiam aos seguintes critérios:

- A classificação/detecção/identificação de raça é um aspecto secundário do estudo (por exemplo, estudos de benchmark) e;
- A implementação/arquitetura do estudo não foi uma contribuição do artigo (por exemplo, estudos de aplicação).

Através desta busca e considerando os critérios de inclusão e exclusão, conforme ilustrado na Figura 2, chegamos a um conjunto de 54 artigos.



Figura 2: Fluxograma de seleção de artigos da revisão bibliográfica

2.3.1 Que estratégias têm sido utilizadas para a classificação racial?

Existem duas categorias amplas de estratégias sendo usadas para determinar a etnia a partir de dados de imagens com base na estratégia de extração de características. A primeira categoria inclui artigos que classificam a etnia com base na avaliação de atributos de textura (consulte Ghalleb et al [66] ou Rasyid et al[67]), manipulação de espaços de cores (consulte [68, 69]) ou o uso de marcos faciais para medir atributos faciais (consulte Xia *et al.* [70]). Nós chamamos essa categoria de Métodos com Suporte de Características Explícitas (EFBM, na sigla em inglês), pois esses métodos dependem de uma representação explícita do rosto antes de avaliar os dados étnicos. As abordagens mais comuns observadas foram o uso de LBPs (Padrões Binários Locais), HOG (Histograma de Gradientes Orientados), medidas de marcos faciais e análise da distribuição de pixels (matrizes de coocorrência de níveis de cinza, momentos de cor e outros).

A segunda categoria apresenta artigos que classificam a etnia com base na extração de características usando algoritmos que obtêm representações intermediárias não legíveis pelo ser humano, como Redes Neurais Convolucionais (CNNs, consulte Wu et al [71] ou Sunitha et al [72]) e outras arquiteturas profundas, como Redes de Crença Profunda. Nós chamamos essa categoria de Métodos com Suporte de Características Ocultas (HFBM, na sigla em inglês), pois nenhuma representação previamente conhecida é usada para extrair as características do rosto, que fica oculta do investigador. O uso de transferência de aprendizado em CNNs, derivado de modelos pré-treinados como VGG-

16, ResNet e outros, foi uma das abordagens mais utilizadas nessa categoria. De modo geral, as CNNs são comuns nessa categoria.

Independentemente da técnica utilizada para a extração de características, muitas estratégias de classificação foram empregadas nos estudos avaliados (consulte a Tabela 3). Entre elas, os métodos baseados em ANN (Redes Neurais Artificiais) e SVMs (Máquinas de Vetores de Suporte) foram os mais populares, seguidos pelo uso de árvores de decisão ou florestas aleatórias. Embora a maioria dessas estratégias dependa de métodos de aprendizado supervisionado, Achkar et al. [73] transpuseram os pontos de dados para um espaço Kendall e agruparam os dados faciais de acordo com os clusters, que só foram posteriormente relacionados à etnia, sendo notável como um dos poucos estudos a utilizar métodos não supervisionados.

2.3.2 Que raças estão presentes nos estudos?

A maioria dos estudos utilizou rótulos derivados da classificação tradicional das raças. Nesse contexto, os sujeitos asiáticos foram os mais representados, seguidos por brancos, negros e etnias indígenas. Foi observada uma notável sub-representação dos grupos latino/hispânicos e do Oriente Médio. Os grupos "asiático", "branco", "negro" e "indiano" representam cerca de 80% de todas as categorias classificadas nos estudos (ver Figura 3).




Figura 3: Categorias raciais presentes nos estudos encontrados na revisão. O nome das categorias representa o nome reportado nos trabalhos. São diretamente traduzidos para “asiáticos”, “brancos”, “negros”, “indianos”, “latino-hispânicos” e “médio-oriental”.

2.3.3 Que fontes de dados são utilizadas para classificação racial?

Identificamos mais de 30 conjuntos de dados diferentes que foram utilizados para a previsão de raça. Entre os artigos avaliados, era comum ver os autores utilizando um conjunto de dados de propósito geral para a previsão de raça, ou até mesmo utilizando conjuntos de dados dedicados à identificação facial e outras tarefas visuais baseadas em rostos. Muitos estudos não encontraram conjuntos de dados adequados disponíveis na época da publicação e precisaram construir um conjunto personalizado.

O uso de conjuntos de dados cuja finalidade original não é a classificação racial tem como consequência o desbalanceamento das classes avaliadas. De todos os conjuntos avaliados, somente o conjunto *FairFace* apresenta um conjunto abrangente de classes raciais balanceadas, o que significa que os demais conjuntos precisam ser balanceados antes do treinamento, o que nem sempre ocorreu nos estudos observados.

Mais de 1/3 dos estudos compilaram seus próprios conjuntos de dados, o que adiciona mais uma camada de complexidade técnica à tarefa já difícil de classificar a etnia a partir do rosto devido à inconsistência. Muitos conjuntos de dados personalizados foram criados devido à necessidade de ajustar os algoritmos para serem treinados em populações específicas em seus estudos, como observado em Gao et al. [33], Jilani et al. [30], Heng et al. [74] e Srinivas et al. [29]. Em outras situações, a necessidade de um conjunto de dados personalizado se deveu ao tipo de dados específico usado, como em Lv et al. [75]. A tabela 2 mostra os conjuntos de dados mais citados observados.

Tabela 2: Conjuntos de dados encontrados na revisão sistemática

Conjunto de Dados	Número de imagens	Conjunto de dados dedicado?	Publicamente disponível?
UTKFaces dataset	23000	×	✓
ND-Iris-0405	26272	×	✓
Multi-Ethnicity Iris	60310	✓	×
CASIA-Iris V3 Dataset	18197	×	✓
IMP dataset	630*	✓	×
FERET dataset	14126	×	✓
Cohn Kanade	2300	×	✓
CMU Multipie Dataset	7500+	×	✓
BUPT Dataset	1.300.000+	×	✓
Chicago Faces Dataset	597	✓	✓

Pakistani Faces Dataset	463	✓	✓
CMIN Dataset	353	×	×
FRGC v2	4007	×	✓
BU3D-FE	2500	×	✓
Lookalike Dataset	6016	×	✓
MUCT dataset	3755	×	✓
Caltech Dataset	165	×	✓
CVL Dataset	468	×	✓
SCUT-FBP	5500	×	✓
CelebA	20000	×	✓
Morph II dataset	55134	×	✓
CJK Dataset	2315	✓	✓
Regions of China Dataset	1217	✓	×
IMDB Dataset	17954	×	✓
FairFace Dataset	97000	✓	✓
Age, Gender and Ethnicity Dataset	27305	✓	✓
CAS-PEAL	99504	×	
VN-Faces	6100	✓	✓
VMER	3300000	✓	✓

2.3.4 Que tipos de informações faciais são utilizadas?

Sendo uma importante fonte de informações sobre a identidade humana, a escolha da entrada facial para a classificação étnica pode potencializar ou dificultar a capacidade dos algoritmos em determinar corretamente a etiqueta étnica para o rosto apresentado. Observamos 5 tipos de dados faciais utilizados para determinar a etnia de um determinado indivíduo. A Figura 4 resume os tipos de dados utilizados, que serão descritos a seguir:

- Olhos e Íris: O uso de informações exclusivas da área orbital, como a forma dos olhos ou a distância entre eles. Além disso, a cor da íris, sua forma e outras informações relevantes.

- Nariz: O uso de informações sobre a forma e tamanho da ponte nasal, narinas e ponta do nariz.
- Partes do rosto: O uso de partes selecionadas do rosto humano, incluindo, mas não se limitando à região ao redor dos olhos e orelhas, boca e olhos, formato facial e outros.
- Rosto inteiro: O uso de imagens faciais brutas, que podem ou não estar alinhadas, para a classificação étnica. Aqui estão todos os estudos que não recortam o rosto em subáreas.
- Representações tridimensionais: O uso de representações 3D do rosto inteiro ou parcial, que podem ou não ser projetadas em um plano 2D posteriormente.




Figura 4: Informações faciais utilizadas para classificação racial automatizada baseada em imagens. Além da projeção bidimensional das representações tridimensionais da face, estas são as abordagens mais comuns encontradas na literatura.

A maior parte dos estudos utiliza a representação facial completa, porém, para ilustrar alguns exemplos, o trabalho realizado por Mohammad e Al-Ani [76] buscou simplificar o tipo de dados utilizado para classificação racial através da definição de uma região de interesse definida como a região periocular (informações de parte do rosto). A proposta dos autores era que esta abordagem reduziria o requisito computacional necessário para a tarefa, permitindo seu uso em ambientes restritos, como celulares.

Usando informações específicas dos olhos, Singh et al [77] utilizaram informações obtidas a partir da imagem das íris dos olhos para treinar *autoencoders* para determinação da classificação racial. Por sua vez, Lv et al [75] utilizaram informações acerca do formato do nariz obtidas imagem obtida pela projeção da representação tridimensional da face para classificar indivíduos entre asiáticos e não asiáticos. A abordagem conseguiu um resultado de acurácia de 93,3%, que é um achado interessante para o tipo de abordagem utilizada. Estes achados mostram a diversidade de

possibilidades de abordagens aplicadas à tarefa de classificação racial na literatura corrente.

2.3.5 Qual o desempenho destas estratégias?

Existe uma transição direta dos tópicos anteriores em relação aos diferentes graus de sucesso na aplicação das diferentes técnicas de extração de características. Conforme mencionado anteriormente, existem duas principais abordagens para classificar a etnia, divididas de acordo com o método de extração de características. A Tabela 4 mostra os sucessos das abordagens utilizando a precisão como principal método de comparação. A acurácia foi escolhida por ser a métrica mais frequente nos estudos, apesar de fornecer resultados enviesados para conjuntos de dados desequilibrados [78]. Observamos que a maioria dos estudos (46 de 51, ou 85,19%) preferiu relatar a precisão. Outras métricas relatadas foram matrizes de confusão (29,63%), pontuações F1 (20,37%) e curvas ROC (16,67%).

Os estudos que utilizaram EFBM obtiveram melhores resultados quando consideramos a melhor acurácia relatada para uma determinada etnia e a acurácia média. No entanto, o limite inferior é mais alto nos estudos que empregam HFBM, o que significa que, mesmo em condições piores, as abordagens HFBM podem ter um desempenho melhor do que as abordagens EFBM. No geral, a acurácia média dos algoritmos fica em torno de 85%.

A acurácia média reportada nos estudos parece se situar em torno de 85%, com possíveis aumentos nos próximos anos à medida que os métodos HFBM amadurecem. As acurácias individuais relatadas, as características dos conjuntos de dados e as métricas utilizadas por cada artigo podem ser visualizadas no material suplementar deste trabalho, acessível em <https://zenodo.org/record/7430540>.

2.4 Modelos de aprendizado profundo utilizados em tarefas de classificação racial

Considerando a taxonomia apresentada anteriormente, modelos de aprendizado profundo são considerados abordagens HFBM, uma vez que a escolha dos atributos avaliados não está sob o controle do pesquisador, mas acontecem através da extração pela avaliação da própria rede profunda utilizada. Considerando o potencial das abordagens HFBM, a seguir apresentaremos dois importantes modelos utilizados na tarefa de classificação racial, uma vez que este trabalho utilizará destas abordagens para comparar seus resultados com o modelo proposto neste trabalho.

2.4.1 Visual Geometry Group Very Deep Convolutional Network (VGG)

A arquitetura VGG-16 é uma rede neural convolucional (CNN) desenvolvida por Simonyan e Zisserman [79] e introduzida em 2015. A VGG-16 é uma arquitetura que consiste em 16 camadas, combinando camadas convolucionais e completamente conectadas. As camadas convolucionais aplicam filtros convolucionais às imagens de entrada para extrair recursos, enquanto as camadas completamente conectadas são responsáveis por classificar esses recursos. A arquitetura utiliza ativação ReLU após cada camada convolucional para introduzir não-linearidade. A figura 5 apresenta as camadas da rede.




Figura 5: Representação visual das camadas da rede profunda VGG 16. Extraída de Simonyan e Zisserman [79].

A VGG-16 foi projetada para a tarefa de classificação de imagens e obteve resultados notáveis em desafios como o ImageNet [80]. Em termos de desempenho, em 2014, no ImageNet Large Scale Visual Recognition Challenge (ILSVRC), a VGG-16 alcançou uma taxa de erro top-5 de apenas 7,3%, o que a tornou uma das melhores arquiteturas disponíveis na época. A avaliação retrospectiva da VGG-16 contra seu precursor submetido para o ImageNet Challenge de 2012 revelou uma taxa de erro top-5 de 8,0%, destacando sua melhora na habilidade em classificar imagens com precisão em conjuntos de dados amplos e diversificados [82].

A rede possui um total de 138.423.208 parâmetros treináveis, como pode ser visto na tabela 3, arquitetura VGG-16 possui uma demanda de memória relativamente alta devido à sua profundidade e ao número de parâmetros que contém. O tamanho exato em

memória pode variar dependendo da implementação e do framework utilizado, bem como quaisquer otimizações aplicadas. No entanto, como uma estimativa aproximada, o modelo VGG-16 geralmente requer cerca de 528 megabytes (MB) de memória para armazenar seus parâmetros [83].

Tabela 3: Descrição das camadas da arquitetura VGG-16 conforme descrita por Simonyan e Zisserman [79].

VGG16 - Structural Details													
#	Input Image			output			Layer	Stride	Kernel		in	out	Param
1	224	224	3	224	224	64	conv3-64	1	3	3	3	64	1792
2	224	224	64	224	224	64	conv3064	1	3	3	64	64	36928
	224	224	64	112	112	64	maxpool	2	2	2	64	64	0
3	112	112	64	112	112	128	conv3-128	1	3	3	64	128	73856
4	112	112	128	112	112	128	conv3-128	1	3	3	128	128	147584
	112	112	128	56	56	128	maxpool	2	2	2	128	128	65664
5	56	56	128	56	56	256	conv3-256	1	3	3	128	256	295168
6	56	56	256	56	56	256	conv3-256	1	3	3	256	256	590080
7	56	56	256	56	56	256	conv3-256	1	3	3	256	256	590080
	56	56	256	28	28	256	maxpool	2	2	2	256	256	0
8	28	28	256	28	28	512	conv3-512	1	3	3	256	512	1180160
9	28	28	512	28	28	512	conv3-512	1	3	3	512	512	2359808
10	28	28	512	28	28	512	conv3-512	1	3	3	512	512	2359808
	28	28	512	14	14	512	maxpool	2	2	2	512	512	0
11	14	14	512	14	14	512	conv3-512	1	3	3	512	512	2359808
12	14	14	512	14	14	512	conv3-512	1	3	3	512	512	2359808
13	14	14	512	14	14	512	conv3-512	1	3	3	512	512	2359808
	14	14	512	7	7	512	maxpool	2	2	2	512	512	0
14	1	1	25088	1	1	4096	fc		1	1	25088	4096	102764544
15	1	1	4096	1	1	4096	fc		1	1	4096	4096	16781312
16	1	1	4096	1	1	1000	fc		1	1	4096	1000	4097000
Total													138,423,208

No entanto, este tamanho em memória se refere ao armazenamento necessário para os pesos e os vieses do modelo consolidado, não ao uso de memória durante o treinamento ou a inferência. Durante o treinamento, é necessária memória adicional para armazenar as ativações intermediárias e os gradientes, o que pode aumentar ainda mais os requisitos de memória. O uso de memória durante a inferência depende do tamanho do lote (batch size) e das dimensões das imagens de entrada.

Serengil et al [84] desenvolveram um framework para processamento de imagens faciais chamado HyperFace. O framework estende uma implementação anterior, voltada para aplicações de reconhecimento facial, em python, chamada DeepFace [85] . Nesta extensão, Serengil utilizou a arquitetura VGG-16 para classificação racial a partir de imagens de treinamento obtidas do conjunto de dados FairFace. O framework é particularmente interessante pois é uma das poucas ferramentas disponíveis para classificação de etnia disponibilizada através de um módulo python com licença aberta. Alternativas, comerciais, são relatadas no trabalho de Buolamwini e Gebru [86].

Os modelos para classificação treinados neste trabalho serão adaptados da arquitetura VGG, partindo da estrutura e pesos fornecidos por Serengil no framework mencionado anteriormente. Desta forma, este trabalho utiliza-se de aprendizado por transferência (*transfer learning*) para agilizar o treinamento de modelos baseados nas características raciais brasileiras.

2.4.2 Residual Network (Resnet)

Outra arquitetura utilizada para classificação racial é a arquitetura ResNet. A ResNet (Residual Neural Network) é uma arquitetura de rede neural profunda que revolucionou o campo do aprendizado profundo. Introduzida por He et al. em 2015 [87], a ResNet aborda o desafio do desaparecimento do gradiente durante o treinamento de redes profundas, permitindo a construção de modelos mais profundos e eficientes. A principal inovação da ResNet é o uso de conexões residuais, que permitem que as informações fluam diretamente através das camadas, evitando degradação do desempenho à medida que a profundidade da rede aumenta.

A arquitetura da ResNet é construída em torno de blocos residuais, que são a base para a sua profundidade e eficácia. Cada bloco residual consiste em duas camadas convolucionais com ativações não lineares, seguidas por uma conexão de desvio que pula diretamente para a próxima camada. Essa conexão de desvio permite que as informações fluam sem interrupção, preservando as representações de baixo nível. Além disso, a arquitetura emprega uma técnica chamada "bottleneck" para reduzir a complexidade computacional. Os blocos residuais "bottleneck" usam camadas convolucionais 1x1 para reduzir a dimensão espacial dos dados, seguidas por camadas convolucionais 3x3, e, finalmente, outra camada 1x1 para restaurar a dimensão original. Essa estrutura eficiente permite a construção de redes profundas com menos parâmetros [87].

layer name	output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112×112	7×7, 64, stride 2				
conv2_x	56×56	3×3 max pool, stride 2				
		$\begin{bmatrix} 3\times 3, 64 \\ 3\times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3\times 3, 64 \\ 3\times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1\times 1, 64 \\ 3\times 3, 64 \\ 1\times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1\times 1, 64 \\ 3\times 3, 64 \\ 1\times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1\times 1, 64 \\ 3\times 3, 64 \\ 1\times 1, 256 \end{bmatrix} \times 3$
conv3_x	28×28	$\begin{bmatrix} 3\times 3, 128 \\ 3\times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3\times 3, 128 \\ 3\times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1\times 1, 128 \\ 3\times 3, 128 \\ 1\times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1\times 1, 128 \\ 3\times 3, 128 \\ 1\times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1\times 1, 128 \\ 3\times 3, 128 \\ 1\times 1, 512 \end{bmatrix} \times 8$
conv4_x	14×14	$\begin{bmatrix} 3\times 3, 256 \\ 3\times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3\times 3, 256 \\ 3\times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1\times 1, 256 \\ 3\times 3, 256 \\ 1\times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1\times 1, 256 \\ 3\times 3, 256 \\ 1\times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1\times 1, 256 \\ 3\times 3, 256 \\ 1\times 1, 1024 \end{bmatrix} \times 36$
conv5_x	7×7	$\begin{bmatrix} 3\times 3, 512 \\ 3\times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3\times 3, 512 \\ 3\times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1\times 1, 512 \\ 3\times 3, 512 \\ 1\times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1\times 1, 512 \\ 3\times 3, 512 \\ 1\times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1\times 1, 512 \\ 3\times 3, 512 \\ 1\times 1, 2048 \end{bmatrix} \times 3$
	1×1	average pool, 1000 d fc, softmax				
FLOPs		1.8×10 ⁹	3.6×10 ⁹	3.8×10 ⁹	7.6×10 ⁹	11.3×10 ⁹

Figura 6: Descrição das camadas da arquitetura ResNet conforme o número de camadas da rede profunda. Extraído de He et al [87]

A ResNet também introduz a noção de aprendizado residual, em que a saída de cada bloco residual é a soma da entrada original e do desvio calculado pela camada convolucional. Essa formulação permite que a rede aprenda a modificar e ajustar apenas as diferenças residuais entre as representações. A ideia por trás desse aprendizado residual é que a otimização do ajuste residual seja mais fácil do que otimizar o ajuste completo. Isso promove o treinamento mais estável e eficiente de redes profundas, permitindo que a ResNet alcance um desempenho superior em várias tarefas de visão computacional [87]

A arquitetura da ResNet, juntamente com suas variantes, tem sido amplamente adotada e demonstrou resultados impressionantes em diversas tarefas de visão computacional. Em desafios como o Desafio de Reconhecimento Visual da ImageNet, a ResNet alcançou uma precisão de classificação significativamente superior a outras arquiteturas [88]. Além disso, a ResNet mostrou eficácia em tarefas de detecção de objetos, segmentação semântica e outras aplicações relacionadas à visão por computador [87,90].

Similar a VGG, a arquitetura ResNet treinada para a tarefa de classificação racial é disponibilizada pela plataforma Clarifai² [91]. A plataforma é um serviço de inteligência artificial e visão computacional que oferece serviços e ferramentas para análise e compreensão de imagens e vídeos. A Clarifai é amplamente utilizada em diversas aplicações, como análise de mídias sociais, busca de imagens, sistemas de segurança e automação industrial, entre outras aplicações, e fornece uma API para utilização de seus

²<https://clarifai.com/clarifai/main/models/ethnicity-demographics-recognition>

modelos.

2.5 Métricas em Classificação Racial

Finalmente, faz-se necessária uma discussão sobre as métricas utilizadas nos trabalhos de classificação racial por processamento de imagens. Como relatamos no tópico sobre a performance das abordagens de classificação racial, a maior parte dos estudos observados utiliza como métrica o relato da acurácia. A acurácia não é uma métrica adequada para estudos de classificação em conjuntos de treinamento desbalanceados, que como relatamos anteriormente, são comuns em trabalhos de classificação racial.

Matrizes de confusão são uma ferramenta amplamente utilizada para avaliar o desempenho de modelos de classificação, fornecendo uma representação tabular das predições do modelo em relação às classes reais dos dados. Uma matriz de confusão é uma tabela de dimensões $N \times N$, onde N é o número de classes no problema de classificação. Cada célula da matriz representa a contagem de instâncias classificadas de acordo com as combinações possíveis entre as classes reais e as classes previstas pelo modelo. As células da diagonal principal correspondem aos verdadeiros positivos e verdadeiros negativos, enquanto as células fora da diagonal principal correspondem aos falsos positivos e falsos negativos.

Essa representação permite a visualização dos erros de classificação cometidos pelo modelo. A interpretação dos valores da matriz de confusão é a seguinte:

- Um **verdadeiro positivo** (*True Positive*, em inglês, com acrônimo TP) ocorre quando o modelo classifica corretamente uma instância como pertencente à classe positiva. Uma classe “positiva” é a classe para a qual um determinado classificador busca classificar em comparação a outra.
- Um **verdadeiro negativo** (*True Negative*, em inglês, com acrônimo TN) ocorre quando o modelo classifica corretamente uma instância como pertencente à classe negativa. Uma classe “negativa” é a classe distinta da classe “positiva” a ser classificada.

Tanto os verdadeiros positivos quanto os verdadeiros negativos representam os acertos do modelo do classificador. Por sua vez, seus erros podem ser classificados da seguinte forma:

- Um **falso positivo** (*False Positive*, em inglês, com acrônimo FP) ocorre quando o modelo classifica uma instância da classe negativa como pertencente à classe positiva.
- Um **falso negativo** (*False Negative*, em inglês, com acrônimo FN) ocorre quando o modelo classifica uma instância da classe positiva como pertencente à classe negativa.

Um exemplo de matriz de confusão para um problema de classificação binária como poderia ser encontrada em um trabalho de classificação racial onde tentasse determinar se uma pessoa aparenta ser de uma determinada tribo indígena amazônica:

Tabela 4: Exemplo de matriz de confusão

	Pertencente à tribo	Não pertencente à tribo
Pertencente à tribo	<i>Verdadeiro Positivo</i>	Falso Positivo
Não pertencente à tribo	Falso Negativo	<i>Verdadeiro Negativo</i>

Estas matrizes podem ser desenhadas para conjuntos 2x2, 3x3 e assim por diante. A partir destas matrizes, um conjunto de medidas derivadas pode ser obtido, conforme descritas a seguir.

Acurácia: A acurácia é uma medida geral da taxa de acertos do modelo em relação ao número total de exemplos. Ela é calculada como a razão entre o número de predições corretas e o número total de exemplos, apresentada na Equação 1.

$$Acurácia = \frac{VerdadeirosPositivos + VerdadeirosNegativos}{TotaldeExemplos} \quad (\text{Equação 1})$$

Precisão: A precisão mede a proporção de exemplos classificados como positivos corretamente em relação ao total de exemplos classificados como positivos. Essa métrica é útil para avaliar a confiabilidade das predições positivas do modelo apresentado na Equação 2.

$$Precisão = \frac{VerdadeirosPositivos}{VerdadeirosPositivos + FalsosPositivos} \quad (\text{Equação 2})$$

Recall: O recall, também conhecido como sensibilidade, mede a proporção de exemplos positivos que foram corretamente classificados em relação ao total de exemplos positivos.

Essa métrica é útil para avaliar a capacidade do modelo em identificar corretamente os exemplos positivos e apresentada na equação 3.

$$Recall = \frac{VerdadeirosPositivos}{VerdadeirosPositivos+FalsosNegativos} \quad (\text{Equação 3})$$

Score F1: O score F1 é uma medida combinada de precisão e recall. Ele fornece um equilíbrio entre essas duas métricas, calculando a média harmônica entre elas. O score F1 é útil quando se deseja uma métrica única para avaliar o desempenho do modelo, apresentado na equação 4.

$$ScoreF1 = \frac{2 \times Precisão \times Recall}{Precisão + Recall} \quad (\text{Equação 4})$$

Por integrar as avaliações de precisão e recall em uma única avaliação, neste trabalho utilizaremos o Score F1 como a principal forma de comparar os resultados entre os modelos utilizados. Diferentemente da acurácia, que é suscetível a vieses em conjuntos desbalanceados, o score F1 nos permite avaliar com maior segurança os modelos nas avaliações deste trabalho [92].

Além disso, para comparar classificadores, utilizaremos o teste de McNemar [107]. O Teste de McNemar é um teste utilizado quando temos pares de dados relacionados, como diferentes algoritmos de classificação sendo avaliados nos mesmos conjuntos de dados [93]. Ao utilizar o teste de McNemar, podemos determinar se há uma diferença significativa entre as proporções de acertos e erros dos classificadores, permitindo-nos identificar quais modelos são estatisticamente superiores em relação a uma métrica específica, como precisão ou taxa de falsos positivos [94]. Essa abordagem é extremamente útil para selecionar o classificador mais adequado para uma determinada tarefa de aprendizado de máquina, fornecendo informações valiosas para aprimorar a eficácia de aplicações em diferentes domínios.

O teste de McNemar é baseado na distribuição qui-quadrado com um grau de liberdade (χ^2 com 1 df). Quando temos uma tabela 2x2 de dados emparelhados (com elementos a, b, c e d), a tabela de possibilidades fica como apresentada na Tabela 5.

Tabela 5: Exemplo de matriz para o teste de McNemar

	Previsões Corretas Modelo A	Previsões Erradas Modelo A
Previsões Corretas Modelo B	a	b
Previsões Erradas Modelo B	c	d

Ou seja, **a** representa as leituras corretamente identificadas por ambos os classificadores e **d** as leituras erroneamente classificadas por ambos os classificadores. De importante interesse são as variáveis **b** e **c**, que representam situações onde os modelos se desencontram: **b** representam erros do modelo A identificados corretamente pelo modelo B, e **c** representa o seu oposto.

A premissa do teste de McNemar é que, se os classificadores são similares, a probabilidade de divergência (situações **b** ou **c**) entre os classificadores A e B são aleatoriamente distribuídas e seguem a mesma distribuição. Isto significa que se os classificadores possuírem a mesma performance, a razão entre **b** e **c** se aproxima de 1.

Para avaliar a similaridade entre os modelos, o teste de McNemar utiliza a estatística para comparar os modelos apresentada na equação 5.:

$$\chi^2 = [(|b - c| - 1)^2] / (b + c) \quad (\text{Equação 5})$$

Matematicamente, isto significa que se a razão entre **b** e **c** é próxima de 1, ou seja, $b \approx c$, a diferença entre **b** e **c** se aproxima de 0 e $\chi^2 \approx 0$. Similarmente, se a razão é desviada para o infinito ($b \gg c$), a diferença se aproxima de b $\chi^2 \approx b/(b+c)$, mas como ($b \gg c$), $\chi^2 \approx b^2/b \approx b$. Finalmente, se a razão é desviada no sentido oposto, ($b \ll c$), $\chi^2 \approx (-c)^2/c \approx c$.

Essa estatística segue uma distribuição chi-quadrado com um grau de liberdade e pode ser utilizada para calcular o valor p (veja Figura 7), permitindo testar a hipótese nula de que não há diferença significativa entre as proporções.




Figura 7: Exemplo de curvas de distribuição de probabilidade para a distribuição chi-quadrado com diferentes graus de liberdade

A tabela 6 disponibiliza os valores calculados de p a partir do valor da distribuição chi-quadrado com um grau de liberdade fornecida pelo Instituto Nacional de Padrões e Tecnologia dos Estados Unidos (*National Institute of Standards and Technology*, NIST):

Tabela 6: Valores de chi-quadrado para diferentes níveis de significância estatística (p)

	Valor de p desejado					
Graus de Liberdade	0.90	0.10	0.05	0.025	0.01	0.005
1	0.016	2.706	3.841	5.024	6.635	7.879

Estes testes serão utilizados para garantir que possamos analisar nossos resultados de maneira sistemática, avaliando se nossas hipóteses propostas no capítulo 1 foram adequadamente avaliadas, com um valor de significância atribuível ao teste de McNemar.

3 *Dataset Faces da Pindorama: Dataset de faces brasileiras para classificação racial*

Neste capítulo, apresentamos o processo de criação de um conjunto de dados de faces brasileiras, nomeado de "Faces da Pindorama", que incorpora mais de 130 mil imagens contemplando a diversidade das pessoas em território brasileiro, com múltiplas faixas etárias, regiões geográficas e sexos. Ao longo deste percurso, delineamos as etapas envolvidas na compilação deste conjunto de dados, indo desde a seleção e categorização das imagens até a curadoria dos atributos raciais e demográficos.

3.1 *Confecção do Dataset*

A construção de um *dataset* que represente a população brasileira é uma etapa crucial para que seja possível aprimorar os modelos de aprendizado profundo utilizados na tarefa de classificação e evitar vieses indesejados a partir de modelos generalistas. Como foi reportado anteriormente, observa-se na literatura uma escassez de conjuntos de dados de grande volume e representativos para o treinamento de modelos de aprendizado profundo com imagens da população brasileira. Atualmente, o único conjunto reportado contendo exclusivamente faces brasileiras é o *dataset* FEI, que possui somente 200 indivíduos [27, 95].

Discutimos no capítulo 2 como a população brasileira é diversa, possuindo características raciais únicas e variadas devido à sua história multicultural e miscigenação. Essa diversidade é um componente essencial da identidade brasileira e deve ser considerada em qualquer aplicação de classificação racial.

Portanto, um dataset específico para classificação racial brasileira é necessário para captar a concepção racial da sociedade brasileira. Como algoritmos de aprendizado profundo são dependentes dos dados com os quais são treinados, ao utilizar datasets que não representam adequadamente a diversidade racial do Brasil, podemos introduzir vieses discriminatórios nos modelos resultantes.

Isto é, ao evitar o uso de *datasets* com pessoas de outras regiões, minimizamos a possibilidade de transferir vieses e estereótipos presentes em outras populações para a classificação racial brasileira. Uma vez que percepções e concepções raciais podem variar

de um país para outro, torna-se fundamental levar em consideração a singularidade da população brasileira ao treinar modelos de classificação racial.

Assim, ao elaborar um novo *dataset* que abrange a população brasileira, podemos garantir que os classificadores sejam treinados de forma mais precisa e justa. Isso permitirá que os modelos aprendam a reconhecer e classificar com precisão as diferentes características raciais presentes na sociedade brasileira.

Portanto, neste capítulo será apresentada a construção de um novo *dataset* que busca representar a diversidade racial brasileira. Esse conjunto de dados visa permitir o treinamento de classificadores mais adequados à realidade brasileira e que possam contribuir para uma promover uma abordagem mais equitativa e inclusiva nas aplicações de inteligência artificial.

Para a construção deste *dataset*, partimos do conjunto de dados abertos de candidatos do TSE. Este *dataset* armazena informações sobre os candidatos que concorrem a cargos eletivos no Brasil, dando acesso aos dados relacionados a candidatura como nome, partido, cargo e situação de registro dos candidatos. Um dado de grande valor para este trabalho é o fornecimento da foto do candidato disponibilizada para a urna eleitoral.

As informações presentes no *dataset* incluem informações sobre o candidato, como nome completo, inscrição no CPF, inscrição no CNPJ (apenas para candidatos com comitês financeiros registrados), título de eleitor, foto e autodeclaração racial. Além disso, também descrevem detalhes da candidatura, como cargo almejado, partido político, estado e município. Outros dados administrativos da candidatura são fornecidos, mas não têm relevância para as finalidades propostas neste trabalho.

O conjunto de dados possui informações disponibilizadas separadamente para cada período eleitoral bienal (eleições locais e eleições gerais). O Tribunal Superior Eleitoral disponibiliza esses dados por meio do sistema "DivulgaCand", que permite que os usuários acessem e consultem as informações dos candidatos. O *dataset* também permite que os dados possam ser baixados. O conjunto de dados é atualizado regularmente ao longo o período eleitoral e mantém-se estável após o término do processo eleitoral [96].

Como mencionado anteriormente, o conjunto de dados fornece as fotos utilizadas para exibição na urna eletrônica de todos os candidatos registrados. Por serem utilizadas no processo eleitoral e concedidas ao TSE para domínio público (neste caso fornecida

sobre a licença Creative Commons³), estas imagens se tornam acessíveis para os fins desta pesquisa. O acesso e uso destes dados segue todos os preceitos éticos atrelados ao consentimento do uso destes dados [97].

Considerando a abrangência territorial do processo eleitoral, o conjunto de dados fornecido pelo TSE possui imagens de indivíduos brasileiros de todas as regiões, raças e sexo. Desta forma, serve como um importante recurso para a construção do conjunto de dados de faces brasileiras proposto.

Para este estudo, foram utilizados os conjuntos de dados de candidatos de 2016, 2018, 2020 e 2022. As tabelas auxiliares e imagens fornecidas foram coletadas e todas as faces do rosto foram extraídas usando uma cascata de Haar implementada pela biblioteca OpenCV 2, como um candidato pode ter se candidato em mais de uma eleição, o seguinte algoritmo foi utilizado para obter todas as fotos associados à um único CPF – Em cada eleição, o candidato recebe um código eleitoral, mas ainda é unicamente identificado pelo seu CPF.

A partir das informações fornecidas no *dataset*, cada candidato foi identificado unicamente a partir do seu CPF e a partir desta chave, as imagens dos candidatos foram associadas a este registro nas eleições em que o candidato esteve presente. Como um candidato pode ter mudado sua declaração racial ao longo das eleições, é necessário identificar pessoas cuja autodeclaração mantém se consistente ao longo dos anos.

Como não é possível avaliar a consistência de registros únicos, optou-se por remover os candidatos que se candidataram em somente uma eleição e avaliou-se os candidatos que participaram de mais de uma eleição. Embora isto reduza a representatividade do conjunto, foi uma escolha necessária para evitar declarações de caráter oportunista e que não representam a visão de pertencimento racial do candidato. Assim, considerou-se “consistente” o candidato que mantém a autodeclaração racial em todas as eleições em que concorre. Por outro lado, os candidatos que alteram a autodeclaração racial em diferentes eleições são classificados como “inconsistentes” e separados do conjunto.

Após a seleção dos candidatos consistentes, os metadados dos candidatos eram consolidados em um registro único para cada candidato, agrupando as informações de todas as eleições em que o candidato participou. Posteriormente, selecionou-se a imagem mais recente do candidato como imagem de escolha para avaliação no trabalho.

³<http://opendefinition.org/licenses/cc-by/>

3.2 Caracterização estatística do dataset

O conjunto segue a distribuição populacional brasileira, com as categorias raciais próximas das observadas pelo IBGE (figura 8). A distribuição de sexo entre os candidatos, no entanto, não segue a populacional, com uma importante representação majoritariamente masculina, com uma relação aproximada de 1 candidata mulher para cada 3 candidatos homens. Em relação à faixa etária, os candidatos seguem uma distribuição normal, com a média de 47,22 anos e desvio padrão de 10,77 anos, como mostrado na Figura 8.




Figura 8: Distribuição etária dos candidatos presentes no conjunto de dados

Dentre as categorias observadas, cuja distribuição é apresentada na Figura 10, destaca-se a presença de uma categoria chamada “Não Informado”. Esta categoria foi observada devido ao fato do registro da autodeclaração pelo TSE ser facultativo, permitindo aos candidatos não informarem caso desejem (Figura 9).




Figura 9: Distribuição das autodeclarações raciais dos candidatos presentes no conjunto de dados

Ademais, as categorias “Amarela” e “Indígena” somadas não contabilizam 0.5% do corpo total de candidatos registrados. Desta forma, este estudo optou por limitar a análise para as categorias “Branca”, “Parda” e “Preta”. Com este ajuste, o conjunto de dados apresentou uma distribuição de aproximadamente 54% de brancos, 34% de pardos e 8% de pretos, conforme apresentado na Figura 10.




Figura 10: Distribuição das autodeclarações raciais dos candidatos presentes no conjunto de dados após aglutinar as categorias “amarela”, “indígena” e “não informado” como Outros

A partir destas categorias, as imagens foram categorizadas conforme a autodeclaração racial do candidato no ano da eleição, conforme apresentado na Tabela 6, de modo que cada imagem foi anotada unicamente com uma categoria racial disponível.

Além disso, compreendendo o aspecto cultural da percepção racial (por exemplo, a percepção de pertencimento à categoria “branca” em uma região com maioria negra é diferente da percepção em uma região com maioria “branca”), adicionamos ao conjunto de dados a anotação do estado a que cada candidato pertence. Dessa forma, é possível representar de forma geograficamente ajustada as percepções de pertencimento racial das 26 federações do país, proporcionando uma visão mais ampla e diversificada dos candidatos selecionados.

Cabe ressaltar que as imagens utilizadas no conjunto de dados são as mesmas fornecidas para a exibição nas urnas eleitorais. Até a eleição de 2022, as imagens das urnas eleitorais eram exclusivamente disponibilizadas em preto e branco, uma vez que as urnas não possuíam telas coloridas. Em 2022, o modelo de urna eletrônica UE2020 foi disponibilizado para a votação, permitindo que eleitores pudessem fazer a

heteroidentificação racial dos candidatos com maior facilidade [98]. A fim de padronizar as imagens, foi optado por colocar todas as imagens deste *dataset* em escala de cinza, permitindo utilizar imagens de candidatos de eleições anteriores a 2022.

As imagens disponibilizadas pelo TSE foram processadas para estarem frontalizadas e disponibilizadas em escala de cinza, facilitando a análise e uso posterior delas. O resultado deste processo é um conjunto de dados contendo um agrupamento de faces de indivíduos brasileiros, anotados com o registro de autodeclaração racial, para os consistentes e o estado de origem dos indivíduos. A tabela 7 descreve a distribuição de dados do conjunto de dados elaborado, enquanto a Figura 11 apresenta exemplos de imagens categorizadas como brancas, pardas ou pretas

Tabela 7: Descrição estatística das faces do conjunto de dados proposto

Atributo	<i>Quantidade (%)</i>
Pessoas	<i>137.603 (100%)</i>
Raça	
Branca	<i>76.839 (55,84 %)</i>
Parda	<i>50.138 (36,43 %)</i>
Preta	<i>10.626 (7,72 %)</i>
Sexo	
Masculino	<i>32.184 (76,62%)</i>
Feminino	<i>105.419 (23,38%)</i>
Faixa Etária	
18-30	<i>8069 (5,86%)</i>
31-40	<i>30400 (22,09%)</i>
41-50	<i>46275 (33,62%)</i>
51-60	<i>37467 (27,22%)</i>
61-70	<i>13168 (9,57%)</i>
71+	<i>2216 (1,61%)</i>
Região	
Norte	<i>12.503 (9,09 %)</i>
Nordeste	<i>36.230 (26,33 %)</i>
Centro-Oeste	<i>10.045 (7,30 %)</i>
Sudeste	<i>53.013 (38,53 %)</i>
Sul	<i>25.812 (18,76 %)</i>

Em conclusão, o conjunto de dados "FACES da Pindorama" traz uma importante contribuição para projetos que visem avaliar a diversidade racial brasileira. Ao oferecer uma representação de rostos baseada em critérios de idade, sexo e região, esse conjunto de dados preenche uma lacuna crucial na pesquisa de classificação racial brasileira encontrada na literatura. O conjunto estará disponível publicamente⁴ e é um passo significativo em direção a uma abordagem mais holística e representativa na classificação

⁴https://archive.org/details/federalized_brazilian_faces_dataset.tar

racial, oferecendo uma base para uma compreensão mais profunda das nuances da diversidade étnica no país.

BRANCA



PARDA



PRETA



Figura 11: Exemplos de indivíduos presentes no conjunto de dados, representado por categoria de autodeclaração

4 Modelo BRA-RACE: Cristalizando a percepção racial brasileira

Neste capítulo será apresentado o modelo BRA-RACE, que se pauta em uma abordagem baseada na associação entre informações sobre a percepção racial automatizada de um indivíduo e a associação geográfica regional do indivíduo para otimizar a percepção racial com base no contexto social particular onde o indivíduo está inserido.

4.1 Estratégia de melhoria para classificação racial no contexto brasileiro

Em sociedades mais racialmente distribuídas, como Europa ou EUA, os limites entre as categorias raciais tendem a ser mais nítidos e definidos. No entanto, sociedades mais miscigenadas como as da América Latina apresentam limites mais fluidos e menos definidos entre suas categorias raciais [109]. Como vimos no capítulo 2, essa fluidez é resultado de séculos de mistura cultural e étnica, que resultaram em uma ampla diversidade de tons de pele, características físicas e origens étnicas [110].

Conforme as sociedades se miscigenaram, os limites entre as categorias raciais tendem a ficar menos claros, com o pertencimento racial sendo atribuído a questões associadas ao pertencimento racial e a questões de poder entre as relações raciais trazidas pelos relacionamentos de seus pais e comunidades [111]. Esta perda de clareza na delimitação racial gera percepções divergentes sobre o pertencimento dentro das categorias existentes, que podem afetar associações na vida pessoal dos indivíduos, afetando fatores como a empregabilidade de pessoas de negras de pele clara em contraste às de pele escura [112].

Em nossa revisão [17], notamos que abordagens de *ensemble* não foram utilizadas pelos autores. Considerando a complexidade do problema de classificação, o uso de modelos *ensemble* pode promover um resultado melhor em comparação a classificadores simples. De acordo com Breiman [99] em seu artigo "Bagging Predictors", o *ensemble* reduz a variância das previsões, levando a uma maior estabilidade e acurácia geral. Por meio da combinação de múltiplos modelos, estimamos que uma abordagem *ensemble* possa ser capaz de capturar diferentes aspectos da representação racial e explorar suas complexidades. Esta abordagem, portanto, pode permitir a detecção de padrões sutis e a redução de erros sistemáticos que estariam presentes em modelos individuais.

Para construção deste *ensemble*, no modelo proposto a seguir, optamos por

transpor o problema de classificação racial de uma tarefa de classificação multiclasse para uma tarefa de *ensembling*. Para isto, classificadores binários são treinados para discernir o pertencimento de indivíduos entre classes (classificadores do tipo um contra todos) e também o pertencimento de indivíduos entre classes diferentes (classificadores do tipo um contra um).

A proposição desta abordagem, portanto, é definir o pertencimento racial de um indivíduo através da classificação entre os contrastes das categorias raciais existentes, permitindo assim uma representação mais justa do pertencimento racial destas pessoas.

4.2 Definição do modelo

O modelo é constituído a partir da construção por *ensemble* de um conjunto de seis classificadores binários para avaliação do pertencimento a uma determinada categoria racial em relação às demais ou para contrastar o pertencimento entre categorias raciais próximas. Agregado a estes classificadores primários é inserida a informação sobre a região do Brasil de onde o participante está sendo avaliado. A composição destes resultados gera um novo vetor de atributos que é avaliado por um classificador diferente dos originais. A figura 12 apresenta como os componentes deste modelo se relacionam.




Figura 12: Esquematisação do modelo BRA-RACE. O modelo agrega a classificação binária para investigação OvO e OvR das categorias raciais brasileiras, além de agregar as informações geográficas. O novo vetor de atributos é classificado por um classificador simples.

Considerando a complexidade envolvida na definição do pertencimento nas categorias raciais, em particular em relação aos indivíduos pardos, cuja amplitude de características fenotípicas é amplamente heterogênea, a agregação de classificadores binários proposta no modelo BRA-RACE nos permite combinar as previsões dos modelos individuais, buscando melhorar a capacidade de generalização e a estabilidade dos resultados comparados a usar um modelo único, como tem sido realizado na literatura [17].

Para isso, o modelo BRA-RACE se baseia no uso de seis diferentes classificadores que utilizam uma foto centralizada do indivíduo avaliado. Destes, três classificadores avaliam os grupos raciais de maneira binária em relação às todas as demais (*One Versus Rest*, ou OvR), sendo estes os classificadores “Preta” vs “Não preta”, “Branca” vs “Não Branca” e “Pardo” vs “Não Pardo”. Além destes, outros três classificadores que contrastam uma classe contra outra (*One vs One*, ou OvO), sendo “Branca” vs “Preta”, “Preta” vs “Parda” e “Parda” vs “Branca”). Note que todas as classes são cobertas por estes classificadores, conforme pode ser visto na tabela 8:

Tabela 8: Cobertura das categorias avaliadas pelos classificadores binários

	Branca	Parda	Preta
Branca	Branca vs Outros (OvR)	Parda ou Branca (OvO)	Branca ou Preta (OvO)
Parda	Parda ou Branca (OvO)	Parda vs Outros (OvR)	Preta ou Parda (OvO)
Preta	Branca ou Preta (OvO)	Preta ou Parda (OVO)	Preta vs Outros (OvR)

Na primeira parte do modelo, portanto, a imagem do rosto do indivíduo é apresentada de maneira independente aos classificadores, que avaliam se a pessoa pode ser considerada “Preta”, “Parda” ou “Branca” em relação às demais categorias e se ela seria classificada como “Preta ou Parda”, “Branca ou Preta” ou “Branca ou Parda”. Estas saídas formam um vetor de atributos novo sobre as percepções de pertencimento a determinado grupo racial.

Finalmente, o modelo BRA-RACE se fundamenta na premissa que a autopercepção do pertencimento de um indivíduo a um determinado grupo racial pode variar conforme a composição racial onde o indivíduo habita, corroborando a concepção do *Social Shaping of Technology*. Esta premissa permite ajustar situações em que um indivíduo da região norte que se autodeclare branco possa ser percebido como pardo na região sul do país ao considerar que a região sul é uma região com população com maioria racial branca em comparação à região norte, por exemplo.

Assim, além das informações diretamente obtidas pelos classificadores, o modelo também considera a informação sobre a região geográfica do indivíduo da imagem, permitindo ao modelo ajustar suas previsões conforme as percepções regionais de raça. Esta informação pode ser fornecida através da informação da origem do indivíduo, de registros públicos ou mesmo da escolha de considerar que avaliação racial do indivíduo deva se ajustar as percepções de raça da região onde uma aplicação que implemente o modelo for utilizada (ex.: O indivíduo da região norte seria avaliado como se tivesse originado da região sul). Para isto, as regiões são enumeradas e um valor é atribuído conforme a região geográfica do indivíduo.

O produto desta agregação é um vetor contendo sete valores diferentes, que podem tomar 320 configurações possíveis. Este vetor de atributos é apresentado a um segundo classificador, que determina a probabilidade de pertencimento do indivíduo a todos os grupos raciais. Esta probabilidade é dada de 0 a 1, com a soma das três probabilidades (Branca, Parda ou Preta) devendo ser igual a 1.

Note-se que a escolha dos grupos raciais é limitada pela disponibilidade de imagens para realizar a avaliação e consequente treinamento do modelo, e neste trabalho, optou-se por utilizar as três classes majoritárias. Dada uma disponibilidade maior de imagens de indivíduos dos grupos raciais “Indígena” e “Amarelo”, o modelo BRA-RACE poderia ser expandido para comportar seus respectivos classificadores OvO e OvR. No capítulo seguinte, descreve-se a construção de um artefato que implementa o modelo BRA-RACE.

5 Experimentos

Neste capítulo, delineamos de forma minuciosa os experimentos conduzidos para avaliar os objetivos do estudo. Exploramos a capacidade de classificação racial utilizando modelos generalistas e desenvolvemos um modelo adaptado com base na arquitetura VGG-16 (Redes Convolucionais Muito Profundas), aplicando-o diretamente ao conjunto de dados "Faces da Pindorama". Detalhamos o processo de pré-processamento dos dados, a seleção das variáveis relevantes e a configuração do modelo BRA-RACE.

Além disso, apresentaremos desde o treinamento até a validação do modelo, considerando as particularidades da classificação racial no contexto brasileiro. Posteriormente, exploramos as comparações entre as classificações do modelo BRA-RACE e os resultados de heteroidentificação, bem como as análises comparativas com modelos generalistas, destacando discrepâncias entre eficácia e especificidade dos modelos de aprendizado de máquina para classificação racial.

5.1 Cuidados para o treinamento do modelo

Durante o trabalho de pesquisa, alguns cuidados foram tomados para garantir a qualidade e confiabilidade dos resultados: Primeiramente, a partir do conjunto de dados descrito no tópico anterior, realizou-se uma separação de um conjunto de imagens para posterior teste dos dados utilizados para treinamento, visando avaliar o desempenho do modelo em dados não vistos previamente. Essa separação preservou a representatividade das classes presentes no conjunto de dados original, e dentre o quantitativo total dos dados disponíveis, $3/4$ (75%) foram reservados para treinamento e $1/4$ remanescente foi reservado para teste e não mais tocado até as etapas de avaliação dos modelos treinados.

A divisão do conjunto de treinamento em conjuntos de treino e validação foi realizada para avaliar o desempenho do modelo durante o treinamento e ajuste dos hiperparâmetros, caso necessário. Considerando que o *dataset* original não é igualmente balanceado entre as três classes, em todos os modelos treinados neste trabalho optou-se por balancear as classes através de *undersampling*. Através desta técnica, o número de amostras tomadas entre as classes é limitada pela classe com o menor número de amostras. Embora isto possa significar uma perda de informação, ao considerar a disponibilidade de imagens no conjunto de dados original, com aproximadamente 10.000

imagens da classe menos representada (categoria “Preta”), considerou-se o *trade-off* aceitável.

Desta forma, a cada batch de treinamento, tomou-se o cuidado de amostrar uma quantidade balanceada das 3 classes, e após o balanceamento, uma proporção de 75% para treinamento e 25% para validação foi repetida, a fim de se obter uma medida objetiva do desempenho do modelo durante o processo de treinamento em dados que não são utilizados para o treinamento do modelo.

Referente ao ambiente computacional, o trabalho foi realizado no Google Colab utilizando GPU. Essa escolha se deu em vista da necessidade de permitir que os experimentos pudessem ser replicados em um ambiente computacional acessível, buscando viabilizar a replicabilidade e validação do modelo proposto. O ambiente disponibilizado é gratuito para usuários com conta Google e possui 12,7GB de memória RAM, uma CPU Intel(R) Xeon(R) CPU @ 2.20GHz, e uma GPU Nvidia Tesla T4 com 14GB de RAM. A disponibilidade de GPU acelerou o treinamento dos modelos, contribuindo para uma maior eficiência na execução dos experimentos.

Em vista da demanda de restrição do ambiente computacional, alguns ajustes adicionais à arquitetura VGG foram necessários para a possibilidade de treinamento em um ambiente computacional limitado: Enquanto a arquitetura VGG original recebe imagens de entrada com a resolução de 224x224, nossas imagens foram redimensionadas para 64x64 – Esta redução de tamanho permitiu a execução de batches contendo um número significativo de imagens (Figura 13).

Ao rodar batches com o tamanho original da VGG, observou-se que o ambiente computacional esgotava a memória disponível, uma vez que a arquitetura VGG original possui 138M de parâmetros treináveis. Com o ajuste, o número de parâmetros treináveis é reduzido para 39.5M de parâmetros, tornando a tarefa computacionalmente mais simples. Embora a resolução seja reduzida, o que significa que informação seja perdida nesta redução, as características principais da imagem ainda conseguem ser discernidas visualmente. Identificamos que existe um *tradeoff* de qualidade de imagem por número de imagens avaliadas, optando, na construção dos nossos modelos, a maior disponibilidade de exemplos treináveis em detrimento da qualidade da imagem.



Figura 13: Adaptação da rede VGG-16 por redimensionamento. As imagens foram redimensionadas para o mesmo tamanho a fim de comparação visual. A pessoa retratada foi gerada por uma GAN, disponível no site www.thispersondoesnotexist.org

Todos os modelos treinados foram configurados usando a implementação da VGG-16 disponibilizada pelo framework Keras ⁵. O pipeline de treinamento foi configurado para rodar por até, no máximo, 1000 épocas de treinamento, no entanto, a fim de evitar desperdício computacional, um *EarlyStopper* foi configurado para interromper o treinamento caso não houvesse melhorias no aprendizado do modelo através da perda em 100 épocas de treinamento seguidas. O tamanho de batch para cada época de treinamento foi de 512 amostras aleatórias.

5.2 Modelos generalistas conseguem classificar as classificações raciais brasileiras? Avaliando nossa linha de base

A arquitetura VGG aplicada à tarefa de classificação racial pode ser utilizada através da implementação disponibilizada na biblioteca python DeepFace, como vimos na seção 2.4. As categorias raciais disponíveis na biblioteca são Branca (white), Preta (black), Asiática (asian), Indiana (indian), Latino (latino-hispanico) e médio-oriental (middle-eastern). Como estas categorias não coincidem com as utilizadas pelo IBGE, o seguinte mapeamento foi proposto (tabela 9).

A mesma estratégia foi aplicada para o classificador baseado em ResNet disponibilizado pela plataforma Clarifai. A Clarifai possui uma implementação de um

⁵<https://keras.io/api/applications/vgg/#vgg16-function>

classificador racial utilizando a arquitetura ResNet⁶, que foi utilizada para configurar um segundo ponto de comparação com a implementação do BRA-RACE descrita neste tópico. Exceto pela categoria Southeast-Asian (malaio), as categorias raciais presentes no modelo da Clarifai são as mesmas presentes no modelo VGG usado pela biblioteca Deepface e o mesmo mapeamento foi utilizado.

Tabela 9: Mapeamento das categorias raciais para o experimento

Categoria IBGE	Categoria DeepFace
Branca	Branca
Preta	Preta
Parda	Latino + Médio-oriental + Indiano + Sudeste Asiático*
Ignoradas	Asiático

*Somente presente nas categorias da ResNet

Ao apresentar uma amostra aleatória de 15.000 faces do conjunto de dados elaborado para o classificador gerado a partir de dados generalistas, obtivemos os seguintes resultados (figura 14).




Figura 14: Matriz de confusão de classificação para o modelo VGG adaptado disponibilizado pela biblioteca DeepFace.

Observando os dados da VGG na figura 14, pode-se notar que o modelo tem uma forte predileção por categorizar as imagens avaliadas como “pardo”. Esta predileção implica em uma importante tendência de erros de classificação para indivíduos das categorias “Preta” e “Branca”, que se dividem de forma aproximadamente igual entre preditos corretos e “pardos”.

⁶ <https://clarifai.com/clarifai/main/models/ethnicity-demographics-recognition>




Figura 15: Matriz de confusão de classificação para o modelo ResNet adaptado disponibilizado pela ClarifAI.

Usando a arquitetura ResNet, o efeito é levemente atenuado, mas ainda nota-se uma tendência a se classificar as imagens como “pardo”. Diferentemente dos resultados obtidos com a arquitetura VGG, a distribuição de “brancos” e “pardos” está próxima de 3:2, porém, ainda representa uma tendência em agrupar as pessoas como “pardos” (Figura 15).

Este resultado pode ser atribuído à ausência de uma classe representativa direta de pardos nos classificadores utilizados. Ao agrupar 3 categorias (“indiano”, “hispânico” e “médio-oriental”) em uma única, pode nos parecer que o classificador opta com mais frequência pela classe “parda” quando não há certeza suficiente se a pessoa se autodeclara “branca” ou “preta”.

Explorando as classificações nestas categorias, temos que para a VGG os seguintes achados (Figura 16). A categoria “Branca”, quando não identificada como “white”, divide-se em leituras distribuídas entre “latino-hispanic” e “middle-eastern”. Note que uma minoria ainda é vista como “black”. Por sua vez, repetindo para a categoria “Parda”, temos uma ampla predominância de “latino-hispanic” e “middle-eastern”. Finalmente, para a categoria “Preta”, o classificador acerta a grande maioria, mas quando incerto, escolhe a categoria “latino-hispânico”.




Figura 16: Distribuição das categorias atribuídas pela implementação da VGG-16 conforme a autodeclaração racial do indivíduo. A categoria latino-hispânico é observada em quantidade significativa em todas as três categorias, porém, a proporção destas varia conforme o valor autodeclarado. Como exemplo, na categoria “parda” está a maior concentração de indivíduos classificados como latino-hispanicos.

Repetindo o exercício para os resultados obtidos pela ResNet, temos a distribuição observada na figura 17:




Figura 17: Distribuição das categorias atribuídas pela implementação da ResNet conforme a autodeclaração racial do indivíduo. Um fenômeno similar ao observado na VGG-16 acontece com este classificador.

Neste caso, é possível notar que o modelo repete os padrões anteriores, com as imagens “incertas” estando distribuídas entre “latino-hispanic” e “middle-eastern”. Neste caso, é notável que nas categorias “Branca” e “Preta”, a proporção de imagens corretamente classificadas aparenta ser maior. A fim de avaliar estes resultados,

avaliamos as métricas de precisão, recall e score F1 dos modelos generalistas avaliados (tabela 10)

Tabela 10: Resultados de classificação para os modelos generalistas

VGG			
	Precisão	Recall	Score F1
Branca	0.707	0.437	0.541
Parda	0.447	0.785	0.569
Preta	0.892	0.557	0.686
Geral	0.682	0.593	0.599
ResNet			
	Precisão	Recall	Score F1
Branca	0.693	0.581	0.632
Parda	0.453	0.701	0.550
Preta	0.871	0.536	0.664
Geral	0.672	0.625	0.615

Ao analisar os resultados das arquiteturas VGG e ResNet para a classificação de tons de pele em diferentes categorias, destacam-se diferenças interessantes nas métricas de precisão e recall.

Na categoria "Branca", ambas as arquiteturas apresentam precisões semelhantes, com valores de 0,707 (VGG) e 0,693 (ResNet). No entanto, a ResNet possui um recall mais alto, atingindo 0,581, em comparação com o recall da VGG de 0,437. Isso sugere que a ResNet é mais eficaz em identificar corretamente amostras da categoria "Branca", como pudemos inferir a partir do gráfico na tabela 10.

Na categoria "Parda", a VGG registra uma precisão de 0,447, enquanto a ResNet tem uma precisão ligeiramente maior, de 0,453. Entretanto, a ResNet exibe um recall inferior, com um valor de 0,701 em comparação com o recall da VGG de 0,785. Isso implica que a VGG tende a classificar indivíduos como pardos com mais frequência que a ResNet.

Para a categoria "Preta", ambas as arquiteturas alcançam altas precisões (0,892 para VGG e 0,871 para ResNet). A VGG possui um recall de 0,557, enquanto a ResNet registra um recall ligeiramente inferior de 0,536. Isso indica que a VGG é mais precisa na identificação correta da categoria "Preta", embora ambas VGG e ResNet apresentem um recall aceitável.

Quando observamos o desempenho geral, a ResNet mostra um score F1 um pouco superior (0,615) em comparação com a VGG (0,599), indicando um melhor equilíbrio entre precisão e recall para a ResNet em todo o conjunto de dados. Estes resultados servirão como base de comparação para os demais classificadores descritos a seguir.

5.3 Treinamento do Modelo Multiclasse baseado na arquitetura VGG

A primeira abordagem utilizada no estudo foi a replicação da estratégia de treinamento realizada para o classificador disponível na biblioteca DeepFace. Esta arquitetura foi escolhida pelo fato de o autor disponibilizar seu modelo e pesos treinados como código de fonte aberta. Assim, pudemos utilizar o modelo já treinado por Serengil et al [24] para treinar nosso modelo de aprendizado por transferência. Para isso, adaptamos a estrutura experimental de Serengil e apresentamos uma amostra aleatória de 7.500 imagens de cada uma das classes (“Branca”, “Parda” e “Preta”) ao classificador para treinamento.

A figura 18 resume os resultados da abordagem selecionada sobre o conjunto de testes. Este classificador apresenta resultados interessantes para classificação de indivíduos da categoria “Preta”, porém, quase 30% dos indivíduos são classificados incorretamente como autodeclarados brancos ou pardos. Por sua vez, nas demais categorias, os resultados são muito inferiores, com uma probabilidade de classificação correta, para a categoria “Branca”, de aproximadamente 60%.

Um grande desafio é observado para a categoria “Parda”, onde mais indivíduos são classificados incorretamente do que corretamente. Em particular, usando esta abordagem, indivíduos autodeclarados pardos são mais frequentemente confundidos com indivíduos autodeclarados brancos do que indivíduos autodeclarados pretos.




Figura 18: Matriz de confusão de classificação para o modelo VGG-16 adaptado e treinado sobre o conjunto de dados Faces da Pindorama.

Quanto ao desempenho deste classificador, apresenta uma precisão global de 0,6222 e recall global de 0,5733. O Score F1 deste classificador é de 0,5736. Comparado com o classificador anterior, é possível observar que este simplesmente replicar a arquitetura usado em dados não brasileiros para a classificação de indivíduos brasileiros nas categorias “Preta”, “Parda” e “Branca” não é uma solução trivial usando o conjunto de dados de faces brasileiras. A precisão obtida foi pior (0.622 vs 0.672 e 0.682), assim como o recall (0.573 vs 0.593 e 0.625), implicando um score F1 pior (0.573 vs 0.599 e 0.615).

Tabela 11: Resultados de classificação para o modelo VGG treinado sobre o conjunto Faces da Pindorama

	Precisão	Recall	Score F1
Preta	0.605 ± 0.0183	0.697 ± 0.0111	0.648 ± 0.0138
Branca	0.448 ± 0.0240	$0.592 \pm 0,0266$	0.510 ± 0.0249
Parda	0.814 ± 0.0292	0.4288 ± 0.0251	0.561 ± 0.0267
Geral	0.622 ± 0.0237	0.573 ± 0.0207	0.573 ± 0.0281

Comparado com os resultados de outros trabalhos de classificação racial, este modelo é inferior a outras abordagens. Belcar et al [26], reportou um score F1 de 0.794 para 5 classes raciais distintas (branco, negros, asiáticos, indianos e “outros”), com uma queda para 0.614 quando avaliadas 7 classes diferentes (expandindo “outros” para latinos, médio-oriental e sudesteasiático). Resultados superiores a 0.900 foram reportados em estudos usando redes profundas por Sunitha et al [72], Ahmed [68] e Vo et al [106] . É

importante observar que as categorias avaliadas são bastante distintas umas das outras, comparadas com as categorias raciais brasileiras.

5.4 Implementação do Modelo BRA-RACE

A fim de adaptar o pipeline de treinamento utilizado na seção anterior, na etapa de balanceamento do conjunto de treinamento, foi utilizada uma variável para determinar os pares de categorias a serem treinadas para o classificador e tomando-se iguais quantidades de amostras aleatórias dos grupos de modo que os dados do treinamento continham a seguinte proporção de amostras: 50% das imagens da categoria avaliada e 50% das demais categorias, sendo estas balanceadas meio a meio. Este balanceamento significa que, tomada a categoria “Preta” por exemplo, o conjunto de testes de 15000 imagens teria: 7500 imagens de indivíduos autodeclarados pretos, 3750 de indivíduos autodeclarados pardos e 3750 de autodeclarados brancos. Da segunda categoria, atribuiu-se a categoria de “Outros”.

Salvo por estes ajustes, os parâmetros de treinamento permaneceram os mesmos descritos anteriormente. A seguir, são apresentados os resultados para os classificadores treinados.

5.4.1 Classificadores OvR




Figura 20: Matriz de confusão de classificação para o classificador binário OvR Brancas vs Outros, baseado em VGG-16 adaptado e treinado sobre o conjunto de dados Faces da Pindorama.

Quanto às características de performance deste classificador (figura 19), temos que o classificador OvR de pessoas autodeclaradas Brancas possui uma precisão de 0.7784, recall de 0.7033 e um score F1 de 0.7389..



Figura 20: Matriz de confusão de classificação para o classificador binário OvR Pretas vs Outros, baseado em VGG-16 adaptado e treinado sobre o conjunto de dados Faces da Pindorama.

Por sua vez, o classificador OvR treinado para identificar indivíduos autodeclarados Pretos (Figura 20) apresentou os seguintes resultados nas métricas descritas: o valor de precisão obtido foi de 0.8423, o valor de recall foi de 0.8479, com um score F1 de 0.8451.




Figura 21: Matriz de confusão de classificação para o classificador binário OvR Pardas vs Outros, baseado em VGG-16 adaptado e treinado sobre o conjunto de dados Faces da Pindorama.

O último classificador OvR foi o treinado para identificar pessoas autodeclaradas pardas (Figura 21). Seu resultado foi menos expressivo que os demais classificadores OvR, com uma precisão 0.6612, um recall de 0.6915 e um score F1 de 0.6760.

5.4.2 Classificadores OvO

A partir dos resultados para o classificador OvR de pessoas autodeclaradas pardas, passamos ao treinamento dos classificadores OvO para identificar se melhores resultados para discriminação entre pardos e as demais classes avaliadas. Aqui, outra variável foi configurada para a tomada dos pares de categorias avaliadas, com o conjunto de treinamento usado sendo representado por 50% de cada categoria. O primeiro destes classificadores avalia a distinção entre indivíduos autodeclarados pretos e pardos (Figura 22).




Figura 22: Matriz de confusão de classificação para o classificador binário OvO Preta vs Parda, baseado em VGG-16 adaptado e treinado sobre o conjunto de dados Faces da Pindorama.

Como pode ser notado, este classificador consegue discriminar indivíduos autodeclarados pretos e autodeclarados pardos aproximadamente tão bem quanto o classificador OvR de indivíduos autodeclarados pretos. A precisão obtida foi de 0.7871, seu recall foi de 0.8425 e o score F1 foi de 0.8139.

Observando o classificador entre brancas e pardas, o cenário é bastante diferente, com uma queda acentuada na qualidade do classificador. Sua precisão observada é de 0.6382, com recall de 0.7224 e score F1 de 0.6777. Este classificador apresenta resultados aproximados com o classificador OvR de pessoas autodeclaradas pardas, sinalizando que possivelmente, o erro observado neste classificador OvR possa estar relacionado à similaridade percebida pelo classificador entre indivíduos autodeclarados brancos e autodeclarados pardos (Figura 23).




Figura 23: Matriz de confusão de classificação para o classificador binário OvO Branca vs Parda, baseado em VGG-16 adaptado e treinado sobre o conjunto de dados Faces da Pindorama.

Finalmente, avaliamos o resultado em função da comparação entre indivíduos autodeclarados brancos e autodeclarados pretos (Figura 24). Seu resultado foi o melhor observado até agora, com precisão de 0.9224, recall de 0.8733 e score F1 de 0.8972.




Figura 24: Matriz de confusão de classificação para o classificador binário OvO Branca vs Preta, baseado em VGG-16 adaptado e treinado sobre o conjunto de dados Faces da Pindorama.

A partir da conjunção de todos os classificadores apresentados, o classificador *ensemble* proposto como o modelo BRA-RACE foi construído. Além destes classificadores binários, o modelo final agrega às classificações geradas pelo conjunto individual de classificadores as informações geográficas relacionadas, o que será discutido na próxima seção.

5.4.3 Agregação de Informações Geográficas e Agregação do *Ensemble*

Além da leitura dos classificadores, também foram utilizados o estado de origem disponível na ficha do candidato para definir a região geográfica a ser utilizada na leitura pelo modelo. A região geográfica do candidato foi codificada de 1 a 5, da seguinte maneira: 1) Sul; 2) Sudeste; 3) Centro-Oeste; 4) Nordeste; 5) Norte.

Com isso, o vetor representativo é um exemplo para o indivíduo é dado e esta informação então foi utilizada para classificação em um classificador simples, conforme o esquema a seguir. Três abordagens de agregação do *ensemble* foram utilizadas, usando métodos de classificadores já implementados pela biblioteca Python scikit-learn:

1. A primeira utilizou a leitura para identificar um vetor de suporte no espaço vetorial dos resultados de classificação descritos anteriormente através do uso de uma SVM, que chamaremos de *Ensemble SVM*, usando a classe **SVC**, do módulo **sklearn.svm**, que implementa uma máquina de vetor de suporte (em inglês, *Support Vector Machine*, SVM).
2. A segunda se utilizou de uma abordagem de classificação bayesiana a partir dos valores previstos pelos classificadores individuais, usando um classificador bayesiano inocente (naïve bayes classifier), que chamaremos de *Ensemble Bayesiana*. Este classificador utiliza a classe **MultinomialNB**, do módulo **sklearn.naive_bayes**, que implementa um classificador naïve bayes multinomial.
3. A terceira utilizou as entradas recebidas para treinar um classificador baseado em um perceptron multicamada. Esta terceira abordagem denominamos de *Ensemble MLP*, que utilizou a classe **MLPClassifier**, do módulo **sklearn.neural_network**, que implementa um classificador baseado em um perceptron multicamada.

O primeiro classificador, o classificador *Ensemble SVM* foi treinado com 15.000 imagens aleatórias, sendo 5.000 pertencentes a cada uma das classes avaliadas no estudo. Como pode ser observado na figura 25, o classificador encontrou resultados superiores ao classificador multiclasse original descrito no item 4.3. Em termos gerais, a tabela a seguir resume os resultados por classe e o resultado geral do classificador.




Figura 25: Matriz de confusão de classificação para o BRA-RACE, usando um classificador final do tipo SVM, sobre o conjunto de dados Faces da Pindorama.

Comparado com o classificador multiclasse original, que tinha precisão, recall e score F1 de 0.622, 0.573, 0.573, respectivamente, este classificador é superior em todos os parâmetros. Similarmente, contrastado aos classificadores treinados em dados gerais, da biblioteca *DeepFace*, temos que, com valores de Geral, 0.672, 0.625 e 0.615 (na mesma ordem que a anterior), nosso classificador supera o classificador generalista.

Tabela 12: Resultados de classificação para o modelo BRA-RACE, usando SVM, treinado sobre o conjunto Faces da Pindorama

	Precisão	Recall	Score F1
Preta	0.794 ± 0.0102	0.800 ± 0.0114	0.797 ± 0.0107
Branca	0.733 ± 0.0302	0.780 ± 0.0112	0.756 ± 0.0163
Parda	0.628 ± 0.027	0.585 ± 0.0223	0.606 ± 0.0244
Geral	0.718 ± 0.0224	0.721 ± 0.0148	0.719 ± 0.0171

Quando investigamos os resultados obtidos com o classificador *Ensemble Bayes*, treinados sobre a mesma condição experimental, obtivemos os resultados descritos na matriz de confusão (figura 26). Suas métricas estão disponíveis na tabela seguinte, com os resultados de precisão, recall e score F1 deste classificador *Ensemble*.




Figura 26: Matriz de confusão de classificação para o BRA-RACE, usando um classificador final Bayesiano, sobre o conjunto de dados Faces da Pindorama.

Comparado com o classificador anterior, este classificador apresenta resultados agregados piores em todos os eixos. O ganho deste classificador se dá na melhora em discernir exemplos da classe de indivíduos autodeclarados pretos, mas às custas da assertividade nas demais classes.

Tabela 13: Resultados de classificação para o modelo BRA-RACE com classificador Bayesiano, treinado sobre o conjunto Faces da Pindorama

	Precisão	Recall	Score F1
Preta	$0.752 \pm 0,0124$	$0.8846 \pm 0,0138$	$0.813 \pm 0,0130$
Branca	$0.732 \pm 0,0140$	$0.747 \pm 0,0130$	$0.740 \pm 0,0134$
Parda	$0.633 \pm 0,0412$	$0.509 \pm 0,0291$	$0.564 \pm 0,0339$
Geral	$0.706 \pm 0,0224$	$0.714 \pm 0,0186$	$0.706 \pm 0,0334$

Finalmente, avaliamos a terceira abordagem, encapsulada pelo classificador *Ensemble MLP* sob as mesmas condições experimentais dos modelos anteriores. A matriz de confusão (figura 27) mostra uma distribuição melhor entre três classes avaliadas, com o maior valor de classificações corretas de indivíduos pardos dentre todos os modelos apresentados até aqui.




Figura 27: Matriz de confusão de classificação para o BRA-RACE, usando um classificador final do tipo Perceptron Multicamada, sobre o conjunto de dados Faces da Pindorama.

Seus resultados representam o melhor resultado de classificação visto até agora, superando todos os modelos descritos anteriormente em todas as métricas agrupadas. O gráfico a seguir compara os resultados entre os 5 classificadores elaborados.

Tabela 14: Resultados de classificação para o modelo BRA-RACE com classificador MLP, treinado sobre o conjunto Faces da Pindorama

	Precisão	Recall	Score F1
Preta	0.770 ± 0.0328	0.843 ± 0.192	0.805 ± 0.0126
Branca	0.787 ± 0.0228	0.768 ± 0.0387	0.777 ± 0.0239
Parda	0.671 ± 0.0421	0.624 ± 0.0359	0.647 ± 0.0406
Geral	0.743 ± 0.0325	0.745 ± 0.0312	0.743 ± 0.0257

Uma preocupação relevante é que o fator geográfico possa ser o principal contribuidor para categorização de indivíduos, com o ensemble de classificadores binários sendo descartável frente a informação geográfica. Para isso, um experimento de *x-scrambling* foi realizado. Neste experimento, todas as variáveis regionais foram aleatorizadas e o modelo avaliado sob esta nova condição (figura 28). É possível observar que a variável regional é fundamental para aprimorar o discernimento de indivíduos autodeclarados pardos frente as demais categorias.




Figura 28: Resultados do modelo BRA-RACE MLP após x-scrambling.

Finalmente, é importante comparar o desempenho dos modelos a fim de determinar se os resultados encontrados entre os diferentes modelos são diferentes entre si. Primeiramente, comparou-se as leituras realizadas pelos classificadores generalistas em comparação com as leituras obtidas pelo modelo BRA-RACE. Esta comparação é feita utilizando o teste de McNemar, mencionado no capítulo 2.

Neste teste, comparam-se, em uma tabela 2x2, os valores corretamente avaliados pelo classificador A e pelo classificador B, assim como os erros realizados por cada avaliador. Assim, inicialmente, comparamos os modelos generalistas entre si:

Tabela 15: Tabela de McNemar para comparação entre os resultados de classificação do modelo generalista baseado em VGG (Deepface) e ResNet (Clarifai)

	Acertos ResNet	Erros ResNet
Acerto VGG	1135 (45,42%)	347 (13,88%)
Erros VGG	384 (15,36%)	633 (25,34%)

Utilizando os valores de b e c nestes dados encontramos que estes modelos apresentam um valor de chi-quadrado de 1,778, o que significa que o valor de p é superior a 0.05 para estes classificadores, indicando que não há diferença estatística entre os

modelos.

Para fins de comparação, selecionou-se o modelo BRA-RACE utilizando o classificador baseado em um perceptron multicamada (BRA-RACE MLP). Em seguida, comparou-se os resultados obtidos por este modelo e cada um dos modelos generalistas. A tabela 16 exibe a comparação entre o modelo BRA-RACE e o modelo VGG generalista:

Tabela 16: Tabela de McNemar para comparação entre os resultados de classificação do modelo BRA-RACE e o classificador generalista baseado em VGG (Deepface).

	Acertos BRA-RACE	Erros BRA-RACE
Acerto VGG	1230 (42,19%)	253 (10,11%)
Erros VGG	697 (27,90%)	320 (12,90%)

Utilizando os valores de b e c nestes dados encontramos que os modelos apresentam um valor de chi-quadrado de 207,24, o que nos diz que nosso valor de p é inferior a 0.05, o que significa que há uma diferença estatística entre os modelos. Este resultado, apoiado pelos melhores resultados de classificação dão suporte a nossa hipótese não-nula de que modelos generalistas não capturam o fenômeno de classificação racial no Brasil. Repetindo o exercício anterior para o modelo, temos o seguinte resultado, apresentado na tabela 17:

Tabela 17: Tabela de McNemar para comparação entre os resultados de classificação do modelo BRA-RACE e o classificador generalista baseado em VGG (Deepface).

	Acertos BRA-RACE	Erros BRA-RACE
Acerto ResNet	1237 (49,46%)	283 (11,32%)
Erros ResNet	691 (27,63%)	290 (11,59%)

Mais uma vez temos que os resultados do BRA-RACE são diferentes dos obtidos por um modelo generalista: O valor de chi-quadrado encontrado foi de 169,85 e o valor de p derivado deste chi-quadrado foi inferior a 0.05. Estes achados corroboram a hipótese não nula do primeiro teste estatístico deste trabalho.

5.4.4 Autodeclaração e Heteroidentificação: Experimento de pesquisa de opinião

A fim de avaliar a relação entre as respostas do classificador e a percepção de avaliadores externos (heteroidentificação), um novo arcabouço experimental foi elaborado para este estudo. Este arcabouço depende da existência de um modelo treinado em indivíduos brasileiros, como obtivemos na etapa anterior, e de um registro de

percepções realizadas por indivíduos reais. Na literatura, é comum o uso de plataformas de *crowdsourcing*, como o Amazon Mturk, para a captação de respostas de indivíduos [100, 101]. No entanto, a plataforma não está disponível para contratação no território brasileiro [102]

Desta maneira, optou-se por captar as informações sobre a percepção da classificação racial por indivíduos através de um instrumento anônimo. Este instrumento segue as orientações éticas para coleta de opinião anônima, de acordo como CONEP [97] e permitiu que indivíduos fizessem a avaliação da classificação racial de um recorte estratificado por estado dos dados do *Dataset* Faces da Pindorama. O instrumento apresenta uma imagem de um candidato para os participantes do estudo, que opinam sobre a percepção de pertencimento racial do candidato.

O fluxo de interação se dá da seguinte maneira: 1) O participante acessa a página do instrumento, onde recebe instruções sobre o experimento e informações acerca dos aspectos éticos da pesquisa de opinião. Ao desejar participar, o usuário realiza o clique no botão participar, onde será encaminhado para a próxima etapa. Neste momento, uma estratégia simples de um código de sessão é criado e utilizado para identificar os participantes únicos com base na hora e no IP acessado.




Figura 29: Tela inicial do sistema de informação utilizado para coleta dos dados de heteroidentificação pela pesquisa de opinião. A tela inicial apresenta o que é o estudo e qual será a interação esperada do usuário com o sistema de coleta de opinião.

A partir da tela principal, o usuário pode opinar sobre a percepção de pertencimento racial do candidato. A tela principal exibe a foto do candidato em escala de cinza, que é a representação que aparece com maior frequência na urna eletrônica. O nome do candidato é ofuscado, sendo apresentado um código interno para rastreamento

das leituras dos participantes. O participante pode opinar se a pessoa lhe parece Preta, Parda ou Branca e, na ausência de certeza sobre a opinião, ou mesmo o desconforto em responder sobre o candidato apresentado, é facultado o preenchimento ao selecionar a opção “Eu não conseguiria/gostaria de classificar esta pessoa”.



The image shows a web-based survey interface. At the top, the text reads "Como você classificaria esta pessoa?" followed by a smaller line: "Se te perguntassem se a cor da pele dessa pessoa, qual seria sua resposta?". Below this is a grayscale portrait of a man. To the right of the portrait are four horizontal buttons with the following text: "Eu classificaria esta pessoa como PRETA", "Eu classificaria esta pessoa como PARDA", "Eu classificaria esta pessoa como BRANCA", and "Eu não conseguiria/gostaria de classificar esta pessoa". At the bottom left, below the portrait, it says "Candidato #img_185 - Fonte: TSE".

Figura 30: Tela de coleta de opinião do sistema de informação utilizado para coleta dos dados de heteroidentificação pela pesquisa de opinião. O usuário pode optar por classificar o usuário dentro das categorias raciais propostas pelo IBGE ou optar por não responder caso não queira ou não consiga classificar um candidato.

Ao selecionar uma opção, a escolha é registrada e uma nova imagem é carregada para avaliação. Este processo pode ser repetido em até 15 imagens por participante. Ao atingir o número de 15 contribuições, o usuário é notificado, recebe um agradecimento e retorna para a página inicial.

Selecionamos aleatoriamente 5 representantes de cada grupo racial para cada um dos estados brasileiros, de modo que o experimento envolveu um total de 26x5x3 ou 390 imagens representativas. Cada imagem foi apresentada ao conjunto de avaliadores no mínimo 3 vezes e no máximo 5 vezes, onde a opinião sobre o pertencimento do participante foi obtida através do voto da maioria. Nos casos de empate, definiu-se que a opinião dos avaliadores seria considerada inconclusiva.

O recrutamento dos participantes se deu a partir da divulgação da ferramenta entre estagiários e profissionais de uma instituição de pesquisa do Rio de Janeiro. A divulgação orgânica também foi permitida e estes primeiros recrutados puderam encaminhar a divulgação para outros possíveis participantes. Este experimento ocorreu entre janeiro/2023 e maio/2023.

Algumas limitações devem ser consideradas:

1. Devido ao fato de se tratar de uma pesquisa de opinião divulgada entre indivíduos residentes no estado do Rio de Janeiro, é importante destacar que podem existir vieses regionais, ou seja, as respostas podem ser influenciadas por características específicas dessa região, o que pode limitar a generalização dos resultados para outras áreas geográficas.
2. Uma vez que a divulgação possa ter se dado organicamente a partir dos recrutantes iniciais não é possível garantir que todos os respondentes sejam brasileiros, uma vez que não há um mecanismo de verificação efetivo para confirmar a nacionalidade dos participantes devido a restrição não poder coletar dados dos participantes. No entanto, acreditamos que esta probabilidade seja baixa.
3. A utilização do anonimato na pesquisa implica que não temos informações sobre a identidade dos participantes ou sobre a confiabilidade das respostas fornecidas, o que pode afetar a qualidade e a validade dos resultados caso algum dos participantes forneça uma contribuição maliciosa.
4. O número de exemplos selecionados para a pesquisa pode não ser suficiente para representar adequadamente a diversidade de opiniões e características da população em estudo, o que pode levar a conclusões limitadas ou tendenciosas.

Apesar destas limitações, a pesquisa de opinião ensejada neste trabalho permite investigar as relações entre os resultados obtidos nos modelos utilizados neste trabalho e a heteroidentificação racial realizada por terceiros.

5.4.5 Resultados do experimento

Após o experimento ter sido disponibilizado, 1699 avaliações foram realizadas por 120 avaliadores diferentes. Com isto, cada avaliador realizou em média a análise de 14 imagens aleatórias dentro do conjunto de imagens selecionadas. A fim de entender melhor os resultados associados a comparação entre a heteroidentificação e os modelos treinados ou utilizados nos capítulos anteriores, primeiramente comparamos os resultados da votação da maioria dos avaliadores conforme as imagens fornecidas.

Isto é, considerando a heteroidentificação como uma tentativa de classificar as pessoas conforme a percepção racial, podemos considerar a votação da maioria dos participantes do estudo como um classificador, e consequentemente aplicar as mesmas ferramentas para comparar os resultados entre a percepção de pessoas reais e nossos modelos.

A figura 31 representa a matriz de confusão entre as leituras dos avaliadores e as categorias autodeclaradas. Note que a maior parte das amostras classificadas se concentram nas diagonais, indicando uma possível assertividade do modelo. Como um classificador, a votação da maioria apresentou um score F1 de 0.658, o que servirá para comparar os modelos avaliados neste trabalho.

Em particular dois modelos foram utilizados para comparação: Representando os modelos generalistas, utilizamos o modelo baseado em VGG disponibilizado na biblioteca deepface e representando a implementação do BRA-RACE, implementamos a versão do BRA-RACE usando um MLP como classificador final.




Figura 31: Matriz de confusão gerada entre as classificações obtidas pela votação da maioria dos participantes e a raça autodeclarada do candidato na amostra utilizada para o experimento de opinião.

A seguir, podemos ver a matriz de confusão e os resultados para o modelo generalista baseado em VGG. Comparado com a heteroidentificação, é possível notar um maior espalhamento das classificações, onde todas as classes, excepto “Parda” foram classificadas erradas com maior frequência que corretamente. Este classificador apresentou um valor de score F1 de 0.535 no conjunto avaliado.




Figura 32: Matriz de confusão gerada entre as classificações obtidas pelo classificador generalista baseado em VGG (Deepface) e a raça autodeclarada do candidato na amostra utilizada para o experimento de opinião..

Em seguida, repetimos a avaliação usando o classificador baseado no modelo BRA-RACE. Diferentemente do modelo generalista, este modelo avaliou corretamente indivíduos da categoria “Preta” e “Parda” do que incorretamente. Porém, errou com maior frequência do que acertou para a categoria “Branca”. Este classificador, nestas amostras, apresentou um score F1 de 0.602.




Figura 33: Matriz de confusão gerada entre as classificações obtidas pela implementação MLP do BRA-RACE e a raça autodeclarada do candidato na amostra utilizada para o experimento de opinião..

Desta forma, é possível argumentar que a atividade de heteroidentificação foi mais acurada em identificar corretamente os indivíduos do que ambos os classificadores. No entanto, considerando o baixo número de amostras, é importante avaliar se as diferenças

na capacidade de classificação são estatisticamente significativas. Para isto, iremos utilizar novamente o teste de McNemar.

Como tanto o nosso modelo quanto o modelo generalista foram inferiores a heteroidentificação nestas amostras, avaliou-se se os modelos seriam equivalentes neste cenário. Para isto, aplicamos o teste de McNemar nas amostras, com o resultado disponibilizado na tabela 18.

Tabela 18: Tabela de McNemar para comparação entre os resultados de classificação do modelo BRA-RACE e o classificador generalista baseado em VGG (Deepface) na amostra selecionada para o experimento de opinião.

	Acertos BRA-RACE	Erros BRA-RACE
Acerto DeepFace	130	61
Erros DeepFace	85	81

Ao aplicar o teste de McNemar entre as classificações do modelo BRA-RACE e o modelo VGG generalista disponibilizado pelo Deepface, temos que neste experimento que o valor de qui-quadrado foi de 3.94, o que significa que existe uma diferença significativa ($p = 0.0471 < 0.05$) entre os resultados de classificação obtidos pelo BRA-RACE em comparação com o modelo generalista.

Em seguida, repetimos o teste, agora considerando as leituras do BRA-RACE e dos resultados de votação da heteroidentificação. A tabela 19 apresenta os resultados do teste de McNemar nestes dois classificadores:

Tabela 19: Tabela de McNemar para comparação entre os resultados de classificação do modelo BRA-RACE e a heteroidentificação obtida pela votação da maioria na amostra selecionada para o experimento de opinião.

	Acertos BRA-RACE	Erros BRA-RACE
Acerto Heteroidentificação	166	69
Erros Heteroidentificação	49	73

Realizando a avaliação do valor de chi-quadrado desta matriz, temos que o valor de chi-quadrado obtido foi de 3.39. Este valor significa que não existe uma diferença significativa entre a heteroidentificação e o modelo BRA-RACE no teste de McNemar para a classificação ($p = 0.0659 > 0.05$).

Estes resultados significam que nosso modelo se aproxima da percepção por heteroidentificação da classificação racial brasileira. Mesmo considerando as limitações deste estudo, principalmente em relação aos vieses amostrais dos participantes e o

tamanho da amostra, este resultado se torna bastante interessante pois indica que a tarefa de classificação racial de pessoas brasileiras é uma tarefa complexa até para as pessoas.

A fim de contrastar nossos achados com os achados da literatura, utilizamos uma pesquisa conduzida pelo Instituto Brasileiro de Geografia e Estatística em 2008 denominado “Características Étnico-Raciais da População: Um estudo das categorias de classificação de cor ou raça” [103].

Neste trabalho, o órgão coletou informações através de um questionário sobre autodeclaração racial em 6 capitais brasileiras com um número amostral de 15.000 amostras, e no questionário, um dos campos era reservado para que o entrevistador fizesse a heteroidentificação do participante.

As categorias raciais disponíveis não foram as mesmas que as censitárias, pois o campo de coleta da categoria racial foi um campo de preenchimento livre, permitindo expressões espontâneas dos candidatos. A tabela 20 é retirada do estudo e apresenta um sumário dos resultados encontrados no Brasil em relação ao contraste entre heteroidentificação e autodeclaração.

Tabela 20: Distribuição da heteroidentificação de indivíduos conforme a avaliação do entrevistador do IBGE conforme autodeclaração. Adaptado de IBGE, Características Étnico-Raciais da População, 2008

		Autodeclaração (%)							
		Branca	Morena	Parda	Negra	Preta	Amarela	Indígena	Outras
Heteroidentificação (avaliador)	Branca	90,6	25,5	24,2	3,3	1,8	22,1	27,4	57,1
	Morena	1,8	22,4	14,4	11,5	8,5	5,8	12,6	8,8
	Parda	6,3	40,4	54,2	17	22,9	7,7	34,2	24,7
	Negra	0,2	8,2	5,3	63,7	42,9	0,3	6,1	5,1
	Preta	0	1,6	0,8	3,3	20,9	0	0	0,3
	Amarela	0,3	0,3	0,1	0	0	64,1	0	0,8
	Indígena	0	0,4	0,2	0	0,8	0	18	0,4
	Outras	0,7	1,4	0,9	1,1	2,1	0	1,6	2,7

Como mencionado, o campo de autodeclaração neste trabalho foi um campo livre e representações como “Morena” e “Negra” surgiram. Como estas categorias não fazem parte das categorias oficiais do IBGE, abaixo segue a mesma tabela, porém, agrupando “Pardo” como a média de pardos e morenos e “Preta” como a agregação de negros e pretos.

Tabela 21: Distribuição da heteroidentificação de indivíduos conforme a avaliação do entrevistador do IBGE conforme autodeclaração, após agregação das categorias não oficiais.

	Branca	Parda	Preta	Outras
Branca	90,6	24,85	2,55	35,53
Parda	8,1	65,7	29,95	31,27
Preta	0,2	7,95	65,4	3,93

Outras	1,0	1,65	2,0	29,20
--------	-----	------	-----	-------

Interpretando este dado como uma matriz de confusão, podemos calcular o score F1 desta abordagem e avaliar o quanto estes dados diferem dos nossos achados no experimento de opinião. Excluindo as outras e recalculando os percentuais, temos o seguinte cenário, onde o score F1 obtido é de 0.749. Este score F1 é próximo ao score do BRA-RACE no conjunto de testes do estudo. Diferentemente do score F1 obtido em nosso experimento de opinião, que só possuiu 1699 avaliações, este trabalho contou com pelo menos 15000 avaliações independentes.

Tabela 22: Distribuição da heteroidentificação de indivíduos conforme a avaliação do entrevistador do IBGE conforme autodeclaração, após agregação das categorias não oficiais.

	Branca	Parda	Preta
Branca	91,61%	25,23%	2,60%
Parda	8,19%	66,70%	30,59%
Preta	0,20%	8,07%	66,80%

Estes dados corroboram para o entendimento da complexidade da tarefa de classificação racial em um contexto de miscigenação racial complexa, como é o caso do Brasil. Levando em conta os resultados obtidos neste experimento, e com as ressalvas da limitação do estudo, é possível sugerir que o modelo de classificação racial proposto apresenta desempenho comparável a executar a heteroidentificação para fins de classificar indivíduos conforme a sua autopercepção racial.

5.4.6 O Espelho biométrico

Utilizando o modelo proposto neste projeto, apresentamos um sistema de informação para aprofundar a discussão acerca da percepção entre as concepções socialmente concebidas de pertencimento racial e o uso de modelos de aprendizado de máquina para classificação racial. Este sistema, denominado “Espelho biométrico” é uma ferramenta inspirada no trabalho de Wouters et al. [113], onde um caso de estudo ético foi utilizado para avaliar como modelos de inteligência artificial podem gerar primeiras impressões que afetam a vida dos indivíduos sem a possibilidade de controle ou gestão destas impressões.




Figura 34: Tela de exemplo do espelho biométrico de Wouters et al. Extraído de [113]

A fim de avaliar como a percepção de pertencimento racial se correlaciona com os achados do modelo, elaboramos o Espelho Biométrico para que fosse possível que o usuário fizesse a avaliação da sua imagem pelo modelo de aprendizado de máquina. Ao acessar o sistema, o usuário deve permitir o acesso a webcam, e tendo o feito, é recebido pela tela principal do sistema (figura 35).

Nesta tela, o usuário recebe uma breve descrição sobre o experimento do espelho biométrico, sendo informado sobre como sua imagem será utilizada. Após esta descrição existe um botão onde o usuário pode optar por que sua imagem seja avaliada. Sem este consentimento, o experimento não é iniciado e nenhuma imagem é avaliada. Adicionalmente, a fim de garantir a privacidade do usuário, nenhuma imagem é salva pela aplicação. Desta forma, a imagem submetida pelo usuário é avaliada pelo modelo e imediatamente descartada, sendo retornadas ao usuário as leituras realizadas pelo modelo.



Figura 35: Tela inicial do espelho biométrico desenvolvido sobre o BRA-RACE.

Simulando o projeto de Wouters et al., o espelho biométrico avalia quatro informações obtidas a partir da imagem do usuário, sendo estas a idade percebida, o sexo percebido, a raça percebida e a emoção aparente. Salvo pela raça, as leituras são realizadas pelo módulo *Analyze* da biblioteca *Deepface*, já apresentada neste trabalho (Figura 36).

Após a obtenção do consentimento, a leitura é realizada e os resultados são retornados ao usuário, que observa como modelos de aprendizado de máquina o classificariam em relação à idade, sexo, raça e emoção. Nesta tela, o usuário pode concordar ou discordar das leituras realizadas pelo modelo e em particular, pode fornecer a categoria racial a qual o participante se autodeclara (Figura 37).





Figura 36: Tela de avaliação das leituras do espelho biométrico desenvolvido sobre o BRA-RACE.

A aplicabilidade do espelho biométrico é transversal, principalmente em relação às considerações éticas e sociais relacionadas ao uso da IA. No âmbito social, o espelho biométrico pode desempenhar um papel crucial ao conscientizar sobre os vieses algorítmicos e preconceitos inerentes aos modelos de IA facultando aos usuários a possibilidade de confrontar e questionar essas representações. No contexto acadêmico, a ferramenta pode ser empregada para aprofundar a investigação sobre a maneira como as pessoas interpretam e reagem às representações geradas por algoritmos, enriquecendo nossa compreensão das interações entre seres humanos e sistemas inteligentes.



Como a IA te vê

A IA te viu como BRANCA(A). Você concorda?

Discordo

Como você se considera?

A IA te viu como sendo do sexo MASCULINO. Você concorda?

Concordo

A IA te atribui uma idade de 27 anos. Você concorda?

Discordo

Qual sua idade?

A IA te achou COM EMOÇÃO NEUTRA no momento. Você concorda?

Concordo

Enviar Feedback

Figura 37: Tela de avaliação e feedback das leituras do espelho biométrico desenvolvido sobre o BRA-RACE.

Espera-se que o espelho biométrico possa apoiar experimentos que avaliem o impacto de sistemas de IA aplicado à questões sociais complexas, como a classificação racial, proporcionando um meio para investigação das interações entre a inteligência artificial, a percepção humana e os contextos sociais relacionados.

6 Discussão

Avaliando a capacidade de generalização de modelos de aprendizado de máquina em relação ao fenômeno de percepção racial em um contexto racialmente complexo, como é o caso brasileiro, a questão central deste trabalho envolve compreender se modelos próprios, treinados a partir de dados locais em contraposição a dados gerais permite alcançar uma melhor representação desse fenômeno.

Esta investigação se pauta na premissa baseada na teoria da modelagem social da tecnologia (*social shaping of technology*), e seus resultados são importantes para o entendimento das implicações de se considerar as contribuições sociais ao treinamento e configuração de modelos de aprendizado de máquina que busquem modelar a complexidade da percepção racial em sociedades complexas.

A primeira das hipóteses nulas deste trabalho determina que exista uma igualdade em termos da capacidade dos modelos generalistas para modelar o fenômeno de classificação racial no Brasil. Isto significa que não haveria diferença entre utilizar modelos treinados em dados representativos do contexto da aplicação e modelos generalistas desde que um mapeamento adequado das classes tenha sido realizado. Este trabalho, no entanto, propõe que o uso de dados locais e a construção de modelos específicos são necessários para captar o fenômeno de classificação racial no Brasil.

Antes de abordar os resultados obtidos, é importante destacar os resultados da revisão sistemática da literatura dedicada aos métodos empregados na classificação racial [17] aplicada neste trabalho, onde foram exploradas diferentes abordagens utilizadas para a classificação racial na literatura recente. Entre as técnicas usadas para classificação racial, observa-se um notável crescimento no uso de técnicas de aprendizado profundo nos últimos anos. A popularidade crescente desse enfoque revela a necessidade de estratégias mais avançadas, capazes de lidar com a complexidade e a variabilidades inerentes aos dados raciais. A revisão bibliográfica deste trabalho contribuiu para a compreensão das tendências recentes e das melhores práticas adotadas na área de classificação racial, oferecendo insights valiosos para a evolução contínua das abordagens de aprendizado de máquina voltadas para essa importante temática.

6.1 Dataset Faces da Pindorama

Dentre os achados da revisão apresentada na seção 2 e com o intuito de permitir que este estudo fosse viabilizado, notou-se uma carência de *dataset* de faces brasileiras disponíveis, onde *dataset* FEI o único disponível, carece de uma quantidade adequada de fotos brasileiras para o treinamento de modelos de aprendizado profundo utilizados na tarefa de classificação racial. Como resposta a essa lacuna, foi necessário elaborar um novo *dataset* específico de faces brasileiras, composto por mais de 100 mil imagens que capturam rostos centralizados de indivíduos provenientes de todas as regiões do país a partir de imagens de candidatos políticos disponibilizadas pelo TSE em domínio público.

Essa etapa foi fundamental para garantir uma representatividade abrangente e diversificada, permitindo uma abordagem mais completa ao fenômeno em análise. O *dataset* elaborado possui indivíduos de todas as regiões do país, com distribuição etária representativa da população adulta e com a informação consistente de autodeclaração racial. A elaboração desse *dataset* personalizado reforça a importância de dados de qualidade e contextualizados para o sucesso de projetos de aprendizado de máquina que buscam compreender nuances culturais e sociais, como é o caso da percepção racial no Brasil.

Os resultados obtidos no estudo só foram possíveis pois este trabalho também objetivou descrever a confecção e padronização de um *dataset* dedicado à classificação racial de indivíduos brasileiros conforme a sua autodeclaração. Este *dataset*, que denominamos Faces de Pindorama possui uma ampla quantidade de faces de pessoas brasileiras cuja declaração racial é consistente ao longo do tempo. Contando com mais de 200.000 faces, o conjunto apresenta uma distribuição etária diversa, mas é desbalanceado em termos de participação racial e participação sexual.

Este conjunto de dados é derivado do conjunto de imagens de candidatos as eleições gerais no Brasil e as características referentes ao desequilíbrio em representação de mulheres e negros é consistente com o reportado na literatura sobre a representatividade destes grupos na política [D1, D2]. O conjunto de dados foi disponibilizado para acesso público e, para a construção de modelos a partir destes dados, é recomendado a aplicação de estratégias para o balanceamento das classes, seja por geração de novas amostras sintéticas (usando redes generativas adversariais, por exemplo) ou por redução do espaço amostral (usando técnicas de undersampling, que foi a escolha tomada neste trabalho) ;

6.2 Avaliação de modelos generalistas para classificação racial brasileira

Em relação aos objetivos deste trabalho, que ensejou investigar a capacidade de generalização da percepção das classificações de raças brasileiras através de modelos de aprendizado de máquina e sua relação com a autopercepção e percepção racial por terceiros, podemos abordar cada um de seus subtópicos.

Em relação a investigação se o uso de modelos de classificação racial generalistas são aplicáveis à realidade racial brasileira, que foi o primeiro dos objetivos específicos, os dados levantados por este estudo apontam que classificadores adaptados de conjuntos de dados generalistas não trazem bons resultados quando aplicados às categorias raciais brasileiras. Estes classificadores tendem a classificar as pessoas como “pardas” com maior frequência do que “brancas” ou “pretas”, o que contribui para um resultado de classificação fraco em uma população amplamente miscigenada como a brasileira.

A estratégia de mapeamento das categorias foi utilizada uma vez que a categoria parda não possui contrapartida direta nas categorias utilizadas pelos classificadores disponibilizados. Uma opção inicial seria classificar hispânicos-latinos como pardos, porém, outras categorias como indianos, árabes e sudeste-asiáticos poderiam ser considerados pardos devido a cor da pele e aspectos associados à imigração no Brasil.

Além de simplesmente adaptar as categorias, também foi ensinado um experimento onde a estrutura do classificador generalista foi utilizada, mas dados locais foram introduzidos a fim de se utilizar a técnica de *transfer learning*. Nossos resultados apontaram que o modelo treinado obteve piores resultados, com um score F1 inferior aos modelos generalistas adaptados.

É possível atribuir o resultado pior do classificador treinado em dados locais em função das características das categorias raciais brasileiras em relação às características das categorias raciais globais. Enquanto as categorias raciais internacionais podem ser avaliadas como mais discretas (ex.: Existem diferenças claras entre asiáticos, brancos, negros e indianos, por exemplo), as categorias raciais brasileiras são menos distintas entre si, com noções de percepção racial mudando regionalmente e conforme a própria concepção de percepção as categorias raciais mistas no Brasil [5,6, IBGE 2008].

6.3 O modelo BRA-RACE como ferramenta dedicada à classificação racial brasileira

Este trabalho também objetivou apresentar e descrever um novo modelo para

classificação racial automatizada de pessoas brasileiras em ambientes computacionais domésticos, denominado BRA-RACE. Este modelo se distingue por sua capacidade de incorporar e ponderar o contraste existente entre diferentes categorias raciais brasileiras. Além disso, uma característica notável do BRA-RACE é a fusão dos dados visuais das imagens com informações geográficas dos indivíduos avaliados, o que permite ajustar a decisão final sobre a classificação racial de indivíduos com base em informações das composições raciais locais.

Ao considerar tanto a diversidade racial quanto o contexto geográfico do Brasil, o modelo BRA-RACE se posiciona como um esforço significativo para aprimorar a precisão e a relevância das classificações raciais automatizadas. A introdução dessa abordagem representa um avanço na área de aprendizado de máquina e busca explorar a rica interseção entre categorias raciais e aspectos geográficos, com o objetivo de proporcionar insights mais contextuais e acurados sobre a percepção racial no contexto brasileiro.

Comparado com os demais modelos testados neste trabalho, a implementação do BRA-RACE usando um perceptron multicamada, chamada BRA-RACE-MLP, foi o modelo com a maior eficácia na detecção das categorias raciais autodeclaradas pelos candidatos, com um score F1 de aproximadamente 0.74. Mesmo com este resultado, o modelo ainda apresenta oportunidades de melhorias no discernimento entre pessoas autodeclaradas brancas e pessoas autodeclaradas pardas.

No entanto, mais uma vez, ressalta-se que esta dificuldade pode estar atrelada à sobreposição entre as categorias raciais brasileiras e as suas percepções ao longo do país mencionadas anteriormente. Um estudo secundário neste trabalho buscou comparar os resultados obtidos pelos modelos de aprendizado de máquina desenvolvidos neste trabalho e resultados de classificação racial gerados por classificadores humanos.

Para isto, ensejou-se um experimento de opinião onde os participantes fizeram avaliações anônimas sobre a opinião do pertencimento racial de um subconjunto de candidatos. Neste experimento, consideramos a votação da maioria dos participantes como saída do classificador e realizamos comparações entre um modelo generalista e o BRA-RACE-MLP. Nossos dados mostram que o BRA-RACE e a percepção dos participantes têm eficácias similares, mensuradas pelo score F1 e são superiores ao uso de um classificador treinado em dados generalistas.

A aplicação do teste de McNemar também permitiu avaliar que a percepção dos participantes e os resultados do BRA-RACE não são estatisticamente diferentes entre si,

porém, ambos diferem das classificações realizadas pelo modelo generalista. Considerando o pequeno número de amostras do experimento e as limitações associadas a ferramenta de coleta de opinião, o estudo não é conclusivo ao realizar comparações entre os modelos, porém, considerando dados de heteroidentificação gerados pelo IBGE, é possível sugerir que o BRA-RACE-MLP é pelo menos tão apto a discernir a raça autodeclarada quanto um grupo de avaliadores humanos.

Estas conclusões são suportadas pelo teste de significância estatística através da distribuição chi-quadrado viabilizada pelo teste de McNemar. Nossos dados mostraram que existe uma diferença estatística significativa ($p < 0.05$) entre os resultados obtidos pelo BRA-RACE e o uso de classificadores generalistas adaptados, invalidando a hipótese nula deste trabalho de que as classificadores generalistas e modelos dedicados a tarefa de classificação racial no Brasil são iguais, e associado aos melhores resultados de classificação observados, significam que estes modelos não são capazes de generalizar bem a classificação racial para o contexto racial complexo do Brasil em comparação a modelos locais.

Em relação às hipóteses estabelecidas no primeiro capítulo, nossos resultados apontam que modelos internacionais utilizados para classificação racial não apresentam um desempenho adequado para a tarefa de classificação racial. Constatamos que os resultados de classificação do modelo BRA-RACE foram superiores aos observados aos classificadores generalistas e através do teste de McNemar, que estes modelos são estatisticamente diferentes.

Assim, assumimos como verdadeira a hipótese não-nula do primeiro teste de que modelos internacionais existentes de reconhecimento racial não apresentam um desempenho aceitável quando submetidos a testes no contexto do Brasil. Secundariamente, também assumimos como verdadeira a hipótese não-nula do segundo teste, que afirma que o uso de um "ensemble" de classificadores binários para cada classe e para a combinação entre elas com um pós-processamento que ajuste a decisão à luz da diversidade geográfica do país, resulta em um aumento significativo no desempenho do classificador e produz resultados satisfatórios.

6.4 O modelo BRA-RACE sob a ótica de SI

Os resultados deste estudo fortalecem a teoria de *Social Shaping of Technology* ao destacar a essencial adaptação das tecnologias de aprendizado de máquina para serem úteis para aplicações dentro do contexto social brasileiro. Em outras palavras, nossos

dados corroboram a interdependência entre a evolução tecnológica e fatores sociais e culturais, evidenciada pela maior eficácia das abordagens que implementam o BRA-RACE em relação à classificação racial feita por classificadores gerais. Isto significa que a capacidade de classificação pode estar ligada às nuances e particularidades locais, sublinhando a necessidade de abordagens que considerem o aspecto social local antes de introduzir soluções de aprendizado de máquina em ambientes sociais complexos, como o brasileiro, visando assegurar a pertinência e aceitação da comunidade.

6.5 Limitações e ameaças à validade

Ao mesmo tempo em que este estudo contribui para a compreensão da sobre o uso de modelos de aprendizado de máquina na tarefa de percepção racial em um contexto racial complexo, é importante reconhecer algumas limitações deste trabalho que podem influenciar as conclusões obtidas por este estudo.

Primeiramente, a exclusão dos grupos étnicos amarelos e indígenas da análise pode impactar a abrangência das conclusões obtidas. A não consideração desses grupos sub-representados impede uma visão holística das dinâmicas raciais no Brasil, uma vez que cada categoria racial desempenha um papel específico na sociedade.

Outra limitação identificada diz respeito ao desequilíbrio nos dados presentes no *dataset* Faces da Pindorama. A disparidade na quantidade de amostras entre as diferentes classes raciais pode introduzir vieses e afetar a confiabilidade dos resultados. Estratégias para equilibrar as classes, como oversampling ou undersampling ponderado, são cruciais para evitar distorções e melhorar a validade das conclusões.

Adicionalmente, a restrição no volume de dados de treinamento, devido ao undersampling, pode impactar a generalização dos modelos. A geração de dados sintéticos, uma abordagem que tem sido usada para contornar a escassez de dados, pode ser uma solução viável para melhorar a eficácia dos modelos de aprendizado de máquina nesse contexto.

Por fim, a inconsistência geográfica nas categorias raciais é uma limitação que merece consideração importante. Esta variação pode introduzir ambiguidade nos resultados, enfatizando a importância de uma abordagem cuidadosa ao aplicar categorias raciais em um país tão diversificado quanto o Brasil. Essa limitação ressalta a necessidade de interpretar as categorias raciais com sensibilidade em contextos culturais complexos.

Adicionalmente, é importante listar algumas ameaças à validade deste estudo, usando a taxonomia descrita no estudo de Baldwin [108]. Primeiramente, existe o viés de seleção de dados: A seleção e aquisição dos dados para o treinamento dos modelos está

atrelada à distribuição dos candidatos eleitorais brasileiros. Esta distribuição demográfica é sabidamente diferente da população brasileira em geral [104, 105] e pode introduzir um viés nos resultados obtidos, especialmente devido a subrepresentação de mulheres e negros no conjunto de dados. Isso pode limitar a generalização das conclusões para a população geral.

Em relação à validade externa, as conclusões obtidas neste estudo podem ter limitações em relação à generalização para outros contextos ou populações que possuem dinâmicas raciais diferentes. A especificidade das características brasileiras pode dificultar a aplicação direta dos resultados em outros cenários culturais. Além disso, amostra dos candidatos eleitorais obtidas para a composição do *dataset* e consequentemente o treinamento dos dados pode não ser representativa. É possível que composições raciais diversas ou mesmo alterações de autodeclaração, que foi critério de seleção dos candidatos no estudo, possam ser diferentes se as eleições escolhidas não fossem as posteriores a 2016.

Outras ameaças, já discutidas em pontos anteriores desta seção envolvem a definição e categorização das classes raciais, que podem variar geográfica e temporalmente, resultando em interpretações diferentes por diferentes avaliadores. Isso pode introduzir ambiguidade e subjetividade na análise. Assim como a medição das características raciais é inteiramente baseada na autodeclaração e, no caso do estudo de opinião, por heteroidentificação. Erros ou subjetividade na coleta dessas características podem afetar a precisão das classificações e consequentemente dos modelos treinados sobre estes dados.

6.6 Trabalhos Relacionados

Em relação a outros estudos com propostas similares a este trabalho, nossos resultados se aproximam dos achados relatados por Al-Humaidan e Prince [35]. Neste estudo, os autores objetivaram criar um conjunto de dados específicos para populações do mundo árabe (Populações do Golfo Árabe, Levantinos e Egípcios) e consequentemente classificar indivíduos conforme estas classificações.

Neste trabalho, similar aos resultados reportados no modelo de aprendizado de máquina adaptado da VGG, treinado somente em dados brasileiros, os autores treinaram uma rede convolucional baseada na arquitetura ResNet e apresentaram dados do seu novo conjunto de dados criado. Os resultados obtidos por Al-Humaidan e Prince foram similares aos encontrados neste trabalho, com resultados médios de acurácia próximos de

57%.

Um fenômeno similar à categoria parda no nosso trabalho foi observado neste estudo, onde uma classe central (no caso deles “GCC”) apresentou uma sobreposição importante com outras classes avaliadas, afetando o resultado final do modelo. Neste cenário, similar ao nosso, também foi observado um importante desequilíbrio entre as classes, porém, diferentemente deste estudo, os autores não aplicaram técnicas de balanceamento do conjunto de dados. Em um segundo experimento no mesmo estudo, apesar de ajustar para equilíbrio das classes, os resultados não melhoraram, sugerindo um fenômeno similar a categoria parda neste estudo.

Outro trabalho com uma proposta similar de solução foi o trabalho desenvolvido por Wing, Ting e Yang [34]. Neste trabalho, os autores propuseram um modelo usando uma arquitetura de *ensemble* para discernir japoneses, coreanos e chineses (tarefa 1) e também aplicou a mesma arquitetura para discernir indivíduos de diferentes subpopulações da china (tarefa 2). Diferentemente deste trabalho, o modelo *ensemble* foi constituído de um conjunto de *autoencoders convolucionais*, que são utilizados para extração de features e posterior classificação dos indivíduos. Este estudo, publicado em 2021, declara-se como o primeiro estudo a realizar classificação racial em nível de províncias.

Em relação a classificação entre japoneses, coreanos e chineses, a abordagem proposta pela equipe de Wing conseguiu uma acurácia de 80.69% para distinção entre as três populações asiáticas, porém quando a mesma arquitetura foi aplicada para subpopulações chinesas, o melhor resultado de classificação dos autores foi uma acurácia de 61.81%. Considerando a acurácia obtida neste estudo, podemos afirmar que o modelo BRA-RACE possui resultados levemente melhores, mas dentro da mesma ordem de grandeza que os autores chineses, evidenciando a dificuldade de classificar indivíduos racialmente por imagens em populações com contextos raciais complexos.

Ainda sobre a população chinesa, Gao et al [33] avaliou o uso de técnicas de aprendizado por transferência usando a arquitetura VGG-16, a mesma utilizada como base para treinamento dos modelos neste trabalho. Os autores conseguiram um resultado ótimo de 80.69% no melhor modelo utilizado para classificação racial dentro das cinco subpopulações avaliadas, porém, assim como no nosso caso, os autores apresentaram piores resultados de classificação para determinados subgrupos (Zhuang e Miao).

Outro estudo envolvendo o estudo de subpopulações asiáticas é o trabalho realizado por Srnivas et al [29]. Neste trabalho, os autores avaliaram duas arquiteturas de

redes convolucionais diferentes a fim de averiguar se elas apresentariam bons resultados na predição de idade, sexo e raça usando seleções de partes do rosto dos indivíduos. Considerando somente os resultados de classificação racial discutidos pelo autor, os classificadores alcançaram resultados muito inferiores aos discutidos até então, com uma acurácia máxima de 24,06% em faces completas e 33,06% usando partes da face. Os resultados obtidos pelo BRA-RACE foram significativamente superiores aos encontrados por Srnivas, porém, sua arquitetura era multitarefa em comparação a nossa arquitetura dedicada.

Resultados interessantes foram obtidos por Putri et al [32], onde uma avaliação da classificação de subpopulações indonésias foi realizada. Diferentemente deste estudo e diferentemente dos demais estudos citados até então, a abordagem utilizada pelos autores foi baseada na extração explícita de atributos através do uso de Padrões Locais Binários Uniformes. Esta estratégia, que utiliza manipulações do espaço de cor RGB para fazer a construção de atributos, logrou uma acurácia máxima de 98,12% usando uma estratégia que utilizou os canais H e S, agrupados em dois bins de 16 valores. Isto forma uma matriz 2x16 de vetores que foi utilizada para a classificação das imagens dos indivíduos indonésios.

Embora a técnica seja promissora, nosso conjunto de dados utiliza somente imagens em escala de cinza decorrentes da limitação de usar imagens de candidatos antes da disponibilização da UE2020, que permite imagens coloridas nas fotos dos candidatos. Um possível trabalho futuro pode envolver a aplicação desta técnica em candidatos nas eleições de 2022 e 2024.

Outro ponto importante é que diferentemente das categorias raciais brasileiras, que surgem do fruto da interação social entre as populações nativas, colonizadores, escravos e imigrantes, as categorias raciais indonésias estão associadas às ilhas de origem do arquipélago indonésio. Embora exista a possibilidade de miscigenação, a categorização está muito mais atrelada à população originária do arquipélago do que as interações raciais entre elas, podendo facilitar o processo de classificação.

Quando a comparação entre populações específicas se amplia para contrastar populações específicas em relação as categorias “gerais” como Branco, Negro, Asiático, os resultados obtidos são melhores. Isto pode ser visto no trabalho desenvolvido por Jilani et al [30].

Neste trabalho, os autores utilizaram um modelo baseado na arquitetura ResNet para classificar indivíduos entre Paquistaneses ou Não-paquistaneses. Em particular, os

não-paquistaneses foram definidos como a amálgama entre as demais categorias raciais presentes no conjunto FERET (brancos, negros, indianos e asiáticos). Neste trabalho, os autores conseguiram uma acurácia máxima de 99,1%, sendo muito superior aos resultados de classificação dos modelos voltados a classificar subpopulações. Um estudo similar é executado por Jewel, Hossain e Tonni [43], onde o objetivo do estudo foi contrastar pessoas entre as raças Bengali e demais. Neste estado, os resultados alcançados foram em torno de 80%, corroborando para a capacidade de discernir populações gerais de grupos raciais específicos.

Em relação a estudos que realizam a classificação racial em geral, a revisão realizada neste trabalho, disponibilizada na seção 2 e também disponível em [17], permite acesso a resultados recentes sobre o estado da arte de projetos dedicados à classificação racial usando aprendizado de máquina.

7 Conclusão

Com base nas análises apresentadas neste estudo, este trabalho traz contribuições substanciais que enriquecem a compreensão das nuances do uso de sistemas baseados em modelos de aprendizado de máquina no contexto da classificação racial em sociedades racialmente complexas como o Brasil. A introdução do modelo BRA-RACE oferece uma abordagem que busca representar a complexidade envolvida nas representações raciais brasileiras, tendo como método o contraste entre categorias raciais brasileiras, mensurados pelos classificadores binários, e associação de informações geográficas.

Essa proposta potencializa a precisão das classificações raciais automatizadas, sugerindo um caminho promissor para lidar com a complexidade das dinâmicas raciais no Brasil. Além disso, a pesquisa enfatiza a relevância da contextualização local na aplicação de modelos de aprendizado de máquina. A necessidade de adaptar a tecnologia às nuances sociais e culturais do Brasil é evidenciada, contribuindo para uma compreensão mais holística da teoria de *Social Shaping of Technology* no cenário de Sistemas de Informação.

Nesse contexto, este estudo não apenas avança o conhecimento na área da classificação racial, mas também fornece diretrizes importantes para o desenvolvimento de abordagens eficazes de aprendizado de máquina em um ambiente tão multifacetado quanto o brasileiro. Ao destacar a importância da adaptabilidade tecnológica e contextual, esse trabalho contribui para a evolução contínua das práticas de aprendizado de máquina, considerando a rica interseção entre tecnologia e sociedade no cenário brasileiro. As conclusões alcançadas fortalecem a base de conhecimento e oferecem uma visão esclarecedora para futuras investigações e aplicações práticas no domínio da classificação racial e além.

7.1 Contribuição da Pesquisa

No âmbito computacional, apresentamos um modelo de classificador *ensemble* que permitiu um ajuste eficaz nos classificadores existentes baseados em aprendizagem de máquina para o contexto de reconhecimento racial brasileiro. Esse modelo não apenas melhorou a precisão dos resultados, mas também ampliou a aplicabilidade do sistema em diferentes subgrupos, representados pelas diferentes regiões brasileiras.

Na área de Sistemas de Informação, nossa contribuição se manifesta na criação de um sistema de reconhecimento racial que alcança um bom desempenho no contexto brasileiro. Esse sistema não apenas supera os desafios técnicos, mas também responde às demandas por resultados confiáveis e pertinentes em aplicações práticas.

Além das dimensões computacionais e tecnológicas, nossa pesquisa tem uma significativa implicação social. Ao explorar a percepção das máquinas e das pessoas em relação à identidade racial, oferecemos *insights* valiosos para compreender como a tecnologia afeta a forma como as pessoas se veem e veem os outros. Essa análise contribui para uma compreensão mais profunda das implicações sociais do reconhecimento racial automatizado, fomentando discussões críticas sobre inclusão, equidade e representatividade.

Portanto, a nossa contribuição abrange áreas cruciais da pesquisa, desde a inovação computacional até as dimensões sociais, refletindo nosso comprometimento em oferecer soluções completas e impactantes que transcendem as fronteiras disciplinares.

7.2 Trabalhos Futuros

Em relação a trabalhos futuros, alguns experimentos adicionais podem expandir sobre os resultados alcançados neste trabalho. Primeiramente, considerando as limitações da pesquisa de opinião executada neste trabalho, uma nova pesquisa de opiniões abrangente, poderia ser conduzida para comparar se o modelo proposto se alinha mais com a percepção externa ou a autodeclaração das categorias raciais. Esse estudo proporciona *insights* valiosos sobre o alinhamento entre classificações automatizadas e as identificações pessoais, elucidando a precisão do modelo BRA-RACE em capturar percepções raciais individuais.

Adicionalmente, a construção de modelos personalizados para as regiões geográficas específicas oferece uma oportunidade de investigar como aspectos sociais regionais afetam a tarefa de classificação racial automatizada em comparação ao modelo global. Ao comparar o desempenho desses modelos regionais com outras abordagens, seria possível avaliar a capacidade de adaptação do BRA-RACE em diferentes contextos socioculturais do Brasil.

Outro estudo de interesse é transpor o problema de classificação racial para um problema de regressão como maneira de extrair atributos. Por fim, a geração de dados sintéticos para corrigir o desbalanceamento das classes apresenta-se como uma direção promissora. Ao aumentar a paridade entre as classes por meio de técnicas como a geração

de novos exemplos de faces por redes adversariais generativas, será possível mitigar os desafios enfrentados pelo *undersampling*, possivelmente aprimorando a robustez do modelo proposto.

8 Referências

- [1] IBGE | Biblioteca | Detalhes | Características étnico-raciais da população: um estudo das categorias de classificação de cor ou raça : 2008 / IBGE, Coordenação de População de Indicadores Sociais. -. Disponível em: <<https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?id=249891&view=detalhes>>. Acesso em: 15 ago. 2023.
- [2] ANJOS, G. DOS. A questão “cor” ou “raça” nos Censos nacionais. **Indicadores Econômicos FEE**, v. 41, n. 1, 27 set. 2013.
- [3] OSORIO, R. G. O sistema classificatório de cor ou raça do IBGE. **www.ipea.gov.br**, 1 nov. 2003.
- [4] JABLONSKI, N. G. Skin color and race. **American Journal of Physical Anthropology**, v. 175, n. 2, 29 dez. 2020.
- [5] HANNA, A. et al. Towards a critical race methodology in algorithmic fairness. **Proceedings of the 2020 Conference on Fairness, Accountability, and Transparency**, 22 jan. 2020.
- [6] CHOR, D. et al. Context-dependence of race self-classification: Results from a highly mixed and unequal middle-income country. **PLOS ONE**, v. 14, n. 5, p. e0216653, 16 maio 2019.
- [7] THAM, D. S. Y.; BREMNER, J. G.; HAY, D. The other-race effect in children from a multiracial population: A cross-cultural comparison. **Journal of Experimental Child Psychology**, v. 155, p. 128–137, mar. 2017.
- [8] MCKONE, E. et al. Why the other-race effect matters: Poor recognition of other-race faces impacts everyday social interactions. **British Journal of Psychology**, 19 maio 2021.
- [9] XIAO, N. G. et al. Infants Rely More on Gaze Cues From Own-Race Than Other-Race Adults for Learning Under Uncertainty. **Child Development**, v. 89, n. 3, p. e229–e244, 10 abr. 2017.
- [10] WAN, L. et al. Face-blind for other-race faces: Individual differences in other-race recognition impairments. **Journal of Experimental Psychology: General**, v.

146, n. 1, p. 102–122, Jan. 2017.

[11] BRASIL, Lei 12.711, Dispõe sobre o ingresso nas universidades federais e nas instituições federais de ensino técnico de nível médio e dá outras providências.

Disponível em: <https://www.planalto.gov.br/ccivil_03/_ato2011-2014/2012/lei/112711.htm>.

[12] BRASIL, Lei 12.990, Reserva aos negros 20% (vinte por cento) das vagas oferecidas nos concursos públicos para provimento de cargos efetivos e empregos públicos no âmbito da administração pública federal, das autarquias, das fundações públicas, das empresas públicas e das sociedades de economia mista controladas pela União. Disponível em: <https://www.planalto.gov.br/ccivil_03/_ato2011-2014/2014/lei/112990.htm>.

[13] BASSO-POLETO, D.; EFROM, C.; RODRIGUES, M. B. Ações Afirmativas no Ensino Superior: revisão quantitativa e qualitativa de literatura. **Revista Electrónica Educare**, v. 24, n. 1, p. 1–24, 1 jan. 2020.

[14] GOMES, N. L.; SILVA, P. V. B. DA; BRITO, J. E. DE. AÇÕES AFIRMATIVAS DE PROMOÇÃO DA IGUALDADE RACIAL NA EDUCAÇÃO: LUTAS, CONQUISTAS E DESAFIOS. **Educação & Sociedade**, v. 42, 2021.

[15] NEVES, P. S. C. Sistemas de classificação racial em disputa: comissões de heteroidentificação em três universidades públicas brasileiras. **Mana**, v. 28, n. 3, 2022.

[16] GONÇALVES DE JESUS, J.; HOFFMANN, R. De norte a sul, de leste a oeste: mudança na identificação racial no Brasil. **Revista Brasileira de Estudos de População**, v. 37, p. 1–25, 30 nov. 2020.

[17] NASCIMENTO L; SANTOS, G. CRISTINA, A. Machine-based Stereotypes: How Machine Learning Algorithms Evaluate Ethnicity from Face Data. 29 maio 2023.

[18] KOZLOWSKI, D. et al. Avoiding bias when inferring race using name-based approaches. **PLOS ONE**, v. 17, n. 3, p. e0264270, 1 mar. 2022.

[19] WILLIAMS, R.; EDGE, D. The social shaping of technology. **Research Policy**,

v. 25, n. 6, p. 865–899, set. 1996.

[20] GRAHAM, R.; CHOI, K. S. Explaining African-American Cell Phone Usage Through the Social Shaping of Technology Approach. **Journal of African American Studies**, v. 20, n. 1, p. 19–34, 29 set. 2015.

[21] CHOU, L.-C. The Social Selection of the Third Party Payment Technology in China on the Social Shaping of Technology Perspective. **Global Academic Journal of Humanities and Social Sciences**, v. 4, n. 1, p. 29–32, 26 fev. 2022.

[22] STROUD, D.; TIMPERLEY, V.; WEINEL, M. Digitalized Drones in the Steel Industry: The Social Shaping of Technology. **Relations industrielles**, v. 75, n. 4, p. 730, 2020.

[23] BENTHALL, S.; HAYNES, B. D. Racial categories in machine learning. **Proceedings of the Conference on Fairness, Accountability, and Transparency - FAT* '19**, 2019.

[24] SERENGIL, S. I.; OZPINAR, A. HyperExtended LightFace: A Facial Attribute Analysis Framework. **2021 International Conference on Engineering and Emerging Technologies (ICEET)**, 27 out. 2021.

[25] JILANI, S. K. et al. **A Machine Learning Approach for Ethnic Classification: The British Pakistani Face**. Disponível em: <<https://ieeexplore.ieee.org/document/8120317>>. Acesso em: 15 ago. 2023.

[26] BELCAR, D.; GRD, P.; TOMIČIĆ, I. Automatic Ethnicity Classification from Middle Part of the Face Using Convolutional Neural Networks. **Informatics**, v. 9, n. 1, p. 18, 25 fev. 2022.

[27] GRECO, A. et al. Benchmarking deep network architectures for ethnicity recognition using a new large face dataset. **Machine Vision and Applications**, v. 31, n. 7-8, 14 set. 2020.

[28] THOMAZ, C. E.; GIRALDI, G. A. A new ranking method for principal components analysis and its application to face image analysis. **Image and Vision Computing**, v. 28, n. 6, p. 902–913, jun. 2010.

[29] SRINIVAS, N. et al. **Age, Gender, and Fine-Grained Ethnicity Prediction Using Convolutional Neural Networks for the East Asian Face Dataset**.

Disponível em: <<https://ieeexplore.ieee.org/document/7961848>>. Acesso em: 19 mar. 2023.

[30] JILANI, S. K. et al. **On the Ethnic Classification of Pakistani Face using Deep Learning**. Disponível em: <<https://ieeexplore.ieee.org/document/8919083>>. Acesso em: 15 ago. 2023.

[31] TERADA, T.; KIMURA, R.; CHEN, Y. **Three-Dimensional Facial Ethnicity Identification Based on Cylindrical Projection and Deep Learning**. Disponível em: <<https://ieeexplore.ieee.org/document/9730761>>. Acesso em: 15 ago. 2023.

[32] PUTRI, T. T.; RACHMAWATI, E.; STHEVANIE, F. **Indonesian Ethnicity Recognition Based on Face Image Using Uniform Local Binary Pattern (ULBP) and Color Histogram**. Disponível em: <<https://ieeexplore.ieee.org/document/9299103>>. Acesso em: 15 ago. 2023.

[33] GAO, S. et al. **Facial Ethnicity Recognition Based on Transfer Learning from Deep Convolutional Networks**. Disponível em: <<https://ieeexplore.ieee.org/document/9131205>>. Acesso em: 15 ago. 2023.

[34] NG, W. W. Y.; ZHOU, Z.; WANG, T. **Fine-Grained Facial Ethnicity Recognition Based on Dual Convolutional Autoencoders**. Disponível em: <<https://ieeexplore.ieee.org/document/9642208>>. Acesso em: 15 ago. 2023.

[35] AL-HUM Aidan, N. A.; PRINCE, M. A Classification of Arab Ethnicity Based on Face Image using Deep Learning Approach. **IEEE Access**, p. 1–1, 2021.

[36] TEIXEIRA, E. A identidade cultural na pós-modernidade. **Texto & Contexto - Enfermagem**, v. 15, n. 1, p. 162–163, mar. 2006.

[37] BANTON, M. **Racial Theories**. 2. ed. Cambridge: Cambridge University Press, 1998.

[38] **Race - Genetics, Evolution, Anthropology | Britannica**. Disponível em: <<https://www.britannica.com/topic/race-human/Modern-scientific-explanations-of-human-biological-variation#/media/1/488030/52059>>. Acesso em: 15 ago. 2023.

[39] STOLER, A. L. **Race and the Education of Desire: Foucault's History of**

Sexuality and the Colonial Order of Things. [s.l.] Duke University Press, 1995.

[40] BHOPAL, R. The beautiful skull and Blumenbach's errors: the birth of the scientific concept of race. **BMJ**, v. 335, n. 7633, p. 1308–1309, 20 dez. 2007.

[41] MICHAEL, J. S. Nuance Lost in Translation. **NTM Zeitschrift für Geschichte der Wissenschaften, Technik und Medizin**, v. 25, n. 3, p. 281–309, 25 jul. 2017.

[42] **Race in the Making.** Disponível em: <<https://mitpress.mit.edu/9780262581721/race-in-the-making/>>. Acesso em: 15 ago. 2023.

[43] JEWEL, MD.; HOSSAIN, MD. I.; TONNI, T. H. **Bengali Ethnicity Recognition and Gender Classification using CNN & Transfer Learning.** Disponível em: <<https://ieeexplore.ieee.org/abstract/document/9117549>>. Acesso em: 15 ago. 2023.

[44] LIMA, M. A Obra de Carlos Hasenbalg e seu Legado à Agenda de Estudos sobre Desigualdades Raciais no Brasil. **Dados**, v. 57, n. 4, p. 919–933, dez. 2014.

[45] MARQUESE, R. DE B. A dinâmica da escravidão no Brasil: resistência, tráfico negreiro e alforrias, séculos XVII a XIX. **Novos estudos CEBRAP**, n. 74, p. 107–123, 1 mar. 2006.

[46] SANTOS, J. A. DOS. História e cultura afro-brasileira e movimento negro. **Momento - Diálogos em Educação**, v. 22, n. 2, p. 39–64, 2013.

[47] INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA, **Números do Censo 2022.** Disponível em: <<https://censo2022.ibge.gov.br/sobre/numeros-do-censo.html>>. Acesso em: 15 ago. 2023.

[48] SEYFERTH, G. COLONIZAÇÃO, IMIGRAÇÃO E A QUESTÃO RACIAL NO BRASIL. **Revista USP**, v. 0, n. 53, p. 117, 30 maio 2002.

[49] LANZA, A. L.; LAMOUNIER, M. L. A AMÉRICA LATINA COMO DESTINO DOS IMIGRANTES: BRASIL E ARGENTINA (1870-1930). **Cadernos PROLAM/USP**, v. 14, n. 26, p. 90, 9 jun. 2015.

[50] **Censos Demográficos | Memória IBGE.** Disponível em: <[https://memoria.ibge.gov.br/historia-do-ibge/historico-dos-censos/](https://memoria.ibge.gov.br/historia-do-ibge/historico-dos-censos/censos-)>

demograficos.html>.

- [51] CAMARGO, A. D. P. R. O censo de 1872 e a utopia estatística do Brasil Imperial. **História Unisinos**, v. 22, n. 3, 23 nov. 2018.
- [52] OLIVEIRA, L. A. P. DE; SIMÕES, C. C. DA S. O IBGE e as pesquisas populacionais. **Revista Brasileira de Estudos de População**, v. 22, n. 2, p. 291–302, dez. 2005.
- [53] **Durban, 31 de agosto a 8 de setembro de 2001**. [s.l: s.n.]. Disponível em: <http://www.unfpa.org.br/Arquivos/declaracao_durban.pdf>.
- [54] BAILEY, S.; FIALHO, F.; LOVEMAN, M. How States Make Race: New Evidence from Brazil. **Sociological Science**, v. 5, p. 722–751, 2018.
- [55] ABDELWHAB, A.; VIRIRI, S. A Survey on Soft Biometrics for Human Identification. **Machine Learning and Biometrics**, 29 ago. 2018.
- [56] HASSAN, B.; IZQUIERDO, E.; PIATRIK, T. Soft biometrics: a survey. **Multimedia Tools and Applications**, 2 mar. 2021.
- [57] MISRA, P.; JAIN, N.; MANDAL, A. S. **Search space reduction for person recognition using soft biometrics**. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/8340628>>. Acesso em: 15 ago. 2023.
- [58] DE CAROLIS et al. "Towards a Social Robot as Interface for Tourism Recommendations." In *cAESAR*, pp. 28-33. 2020.
- [59] RAMU, T.; SUTHENDRAN, K.; ARIVOLI, T. Machine learning based soft biometrics for enhanced keystroke recognition system. **Multimedia Tools and Applications**, v. 79, n. 15-16, p. 10029–10045, 4 fev. 2019.
- [60] GENG, L. et al. Soft Biometrics in Online Social Networks: A Case Study on Twitter User Gender Recognition. **2017 IEEE Winter Applications of Computer Vision Workshops (WACVW)**, 2017.
- [61] DANTCHEVA, A.; ELIA, P.; ROSS, A. What Else Does Your Biometric Data Reveal? A Survey on Soft Biometrics. **IEEE Transactions on Information**

Forensics and Security, v. 11, n. 3, p. 441–467, mar. 2016.

[62] MELZI, P. et al. **Multi-IVE: Privacy Enhancement of Multiple Soft-Biometrics in Face Embeddings**. Disponível em: <https://openaccess.thecvf.com/content/WACV2023W/DVPBA/html/Melzi_Multi-IVE_Privacy_Enhancement_of_Multiple_Soft-Biometrics_in_Face_Embeddings_WACVW_2023_paper.html>. Acesso em: 15 ago. 2023.

[63] SADHYA, D.; SINGH, S. K. Privacy preservation for soft biometrics based multimodal recognition system. **Computers & Security**, v. 58, p. 160–179, maio 2016.

[64] PAGE, M. J. et al. The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. **British Medical Journal**, v. 372, n. 71, 29 mar. 2021.

[65] GUO, Y. et al. A Survey of Multi-Ethnic Face Feature Recognition. **Proceedings of the 2020 9th International Conference on Computing and Pattern Recognition**, 30 out. 2020.

[66] ASMA; SAFA BOUMAIZA; AMARA, B. Demographic Face Profiling Based on Age, Gender and Race. 1 set. 2020.

[67] HAFIDH FIKRI RASYID; TONNI AGUSTIONO KURNIAWAN; FEBRYANTI STHEVANIE. Mongoloid and Non-Mongoloid Race Classification from Face Image Using Local Binary Pattern Feature Extractions. 1 maio 2018.

[68] AHMED ABDULATEEF MOHAMMED; ATUL SAJJANHAR. Investigation of Gender and Race Classification for Different Color Models. 1 nov. 2017.

[69] PUTRIANY, D. M.; RACHMAWATI, E.; STHEVANIE, F. Indonesian Ethnicity Recognition Based on Face Image Using Gray Level Co-occurrence Matrix and Color Histogram. **IOP Conference Series: Materials Science and Engineering**, v. 1077, n. 1, p. 012040, 1 fev. 2021.

[70] XIA, B.; BEN AMOR, B.; DAOUDI, M. Joint gender, ethnicity and age estimation from 3D faces. **Image and Vision Computing**, v. 64, p. 90–102, ago. 2017.

[71] WU, X. et al. **Race Classification from Face using Deep Convolutional**

Neural Networks. Disponível em: <<https://ieeexplore.ieee.org/document/8610704>>. Acesso em: 15 ago. 2023.

[72] SUNITHA, G. et al. Intelligent deep learning based ethnicity recognition and classification using facial images. **Image and Vision Computing**, v. 121, p. 104404, maio 2022.

[73] ACHKAR, R. et al. **Ethnicity Recognition System using Back Propagation Algorithm of an MLP**. Disponível em: <<https://ieeexplore.ieee.org/document/8851071>>. Acesso em: 15 ago. 2023.

[74] HENG, Z.; DIPU, M.; YAP, K.-H. **Hybrid Supervised Deep Learning for Ethnicity Classification using Face Images**. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8351370?casa_token=pt_cRpIyLyEAAAAA:Zynd-4o4-aUbM0nSmbINh9h6_W8yi6oQSFCkngGkyV7HU-aN_Iyn1H4ItU2X1Bw9_95KLG0kNs>. Acesso em: 15 out. 2022.

[75] LV, C. et al. 3D Nose shape net for human gender and ethnicity classification. **Pattern Recognition Letters**, v. 126, p. 51–57, 1 set. 2019.

[76] MOHAMMAD, A. S.; AL-ANI, J. A. **Convolutional Neural Network for Ethnicity Classification using Ocular Region in Mobile Environment**. Disponível em: <<https://ieeexplore.ieee.org/document/8674194>>. Acesso em: 15 ago. 2023.

[77] SINGH, M. et al. Gender and ethnicity classification of Iris images using deep class-encoder. **arXiv (Cornell University)**, 1 out. 2017.

[78] BRANCO, P.; TORGO, L.; RIBEIRO, R. P. A Survey of Predictive Modeling on Imbalanced Domains. **ACM Computing Surveys**, v. 49, n. 2, p. 1–50, 13 ago. 2016.

[79] SIMONYAN, K.; ZISSERMAN, A. **Very Deep Convolutional Networks for Large-Scale Image Recognition**. Disponível em: <<https://arxiv.org/abs/1409.1556>>.

[80] **ILSVRC2014 Results**. Disponível em: <<https://image-net.org/challenges/LSVRC/2014/results>>.

[81] FERGUSON, M. et al. **Automatic localization of casting defects with convolutional neural networks**. Disponível em:

<<https://ieeexplore.ieee.org/abstract/document/8258115>>. Acesso em: 28 dez. 2021.

[82] **ImageNet Challenge 2012 Analysis**. Disponível em: <<https://www.image-net.org/challenges/LSVRC/2012/analysis/>>. Acesso em: 15 ago. 2023.

[83] RHU, M. et al. **vDNN: Virtualized Deep Neural Networks for Scalable, Memory-Efficient Neural Network Design**. [s.l: s.n.]. Disponível em: <<https://arxiv.org/pdf/1602.08124.pdf>>. Acesso em: 15 ago. 2023.

[84] SERENGIL, S. I.; OZPINAR, A. HyperExtended LightFace: A Facial Attribute Analysis Framework. **2021 International Conference on Engineering and Emerging Technologies (ICEET)**, 27 out. 2021.

[85] SERENGIL, S. I. **deepface: A Lightweight Face Recognition and Facial Attribute Analysis Framework (Age, Gender, Emotion, Race) for Python**. Disponível em: <<https://pypi.org/project/deepface/>>.

[86] BUOLAMWINI, J.; GEBRU, T. **Gender Shades: Intersectional Accuracy Disparities in Commercial Gender Classification**. Disponível em: <<https://proceedings.mlr.press/v81/buolamwini18a.html>>.

[87] HE, K. et al. **Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification**. [s.l: s.n.]. Disponível em: <<https://arxiv.org/pdf/1502.01852.pdf>>.

[88] RUSSAKOVSKY, O. et al. **ImageNet Large Scale Visual Recognition Challenge**. Disponível em: <<https://arxiv.org/abs/1409.0575>>.

[89] SHAFIQ, M.; GU, Z. Deep Residual Learning for Image Recognition: A Survey. **Applied Sciences**, v. 12, n. 18, p. 8972, 7 set. 2022.

[90] LIN, H.; JEGELKA, S. **ResNet with one-neuron hidden layers is a Universal Approximator**. Disponível em: <<https://arxiv.org/abs/1806.10909>>. Acesso em: 15 ago. 2023.

[91] CLARIFAI, I. **Enterprise AI Powered Computer Vision Solutions | Clarifai**. Disponível em: <<https://www.clarifai.com/>>.

[92] MAHMUDAH, K. R. et al. Classification of Imbalanced Data Represented as

Binary Features. **Applied Sciences**, v. 11, n. 17, p. 7825, 25 ago. 2021.

[93] DIETTERICH, T. G. Approximate Statistical Tests for Comparing Supervised Classification Learning Algorithms. **Neural Computation**, v. 10, n. 7, p. 1895–1923, out. 1998.

[94] DEMŠAR, J. Statistical Comparisons of Classifiers over Multiple Data Sets. **Journal of Machine Learning Research**, v. 7, p. 1–30, 2006.

[95] **Carlos Eduardo Thomaz - Personal Web Page**. Disponível em: <<https://fei.edu.br/~cet/facedatabase.html>>.

[96] **Divulgação de Candidaturas e Contas Eleitorais**. Disponível em: <<https://divulgacandcontas.tse.jus.br/divulga/#/>>.

[97] Conselho Nacional de Saúde, **Resolução 512/2016**. Disponível em: <https://bvsms.saude.gov.br/bvs/saudelegis/cns/2016/res0510_07_04_2016.html>.

[98] MALUNGUINHO E. ,Com fotos coloridas, novas urnas ajudam a reconhecer candidatos negros, **Nós**. Disponível em <<https://encurtador.com.br/aeloG>>

[99] BREIMAN, L. Bagging predictors. **Machine Learning**, v. 24, n. 2, p. 123–140, ago. 1996.

[100] CROWSTON, K. Amazon Mechanical Turk: A Research Tool for Organizations and Information Systems Scholars. **Shaping the Future of ICT Research. Methods and Approaches**, p. 210–221, 2012.

[101] AGUINIS, H.; VILLAMOR, I.; RAMANI, R. S. MTurk Research: Review and Recommendations. **Journal of Management**, v. 47, n. 4, p. 014920632096978, 19 nov. 2020.

[102] MORESCHI, B.; PEREIRA, G.; COZMAN, F. G. The Brazilian Workers in Amazon Mechanical Turk: Dreams and realities of ghost workers. **Revista Contracampo**, v. 39, n. 1, 17 abr. 2020.

[103] ROUSSEFF, D. et al. **INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA -IBGE** rgio da Costa Côrtes Solange Corrêa Onel. [s.l: s.n.].

Disponível em: <<https://biblioteca.ibge.gov.br/visualizacao/livros/liv49891.pdf>>.

- [104] RIOS, F.; PEREIRA, A. C.; RANGEL, P. Paradoxo da igualdade: gênero, raça e democracia. **Ciência e Cultura**, v. 69, n. 1, p. 39–44, mar. 2017.
- [105] **Sub-representação política de mulheres e negros é criticada na CDH.** Disponível em: <<https://www12.senado.leg.br/radio/1/noticia/2019/04/16/sub-representacao-na-politica-prejudica-minorias-mulheres-e-negros-denunciam-participantes-de-debate-na-cdh>>. Acesso em: 15 ago. 2023.
- [106] VO, T.; NGUYEN, T.; LE, C. Race Recognition Using Deep Convolutional Neural Networks. **Symmetry**, v. 10, n. 11, p. 564, 1 nov. 2018.
- [107] MCNEMAR, Q. Note on the sampling error of the difference between correlated proportions or percentages. **Psychometrika**, v. 12, n. 2, p. 153–157, jun. 1947.
- [108] BALDWIN, L. Internal and External Validity and Threats to Validity. [s.l.] **Brill**, 2018.
- [109] CHEN, J. M. et al. To Be or Not to Be (Black or Multiracial or White). **Social Psychological and Personality Science**, v. 9, n. 7, p. 763–772, 28 ago. 2017.
- [110] TENDAYI ACHIUME, E. Racial Borders. **The Georgetown Law Journal**. Disponível em: <https://www.law.georgetown.edu/georgetown-law-journal/wp-content/uploads/sites/26/2022/05/Achiume_RacialBorders.pdf>.
- [111] LICHTER, D. T.; QIAN, Z. Boundary Blurring? Racial Identification among the Children of Interracial Couples. **The ANNALS of the American Academy of Political and Social Science**, v. 677, n. 1, p. 81–94, 25 abr. 2018.
- [112] KREISMAN, D.; RANGEL, M. A. On the Blurring of the Color Line: Wages and Employment for Black Males of Different Skin Tones. **Review of Economics and Statistics**, v. 97, n. 1, p. 1–13, mar. 2015.

ANEXO I - Respostas dos participantes do experimento de opinião

Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	PARDA	PARDA	PARDA	PARDA	5	parda	ohss8	parda	ugt0l	parda	d10h0	parda	ltvq6	parda	cnbbn
	BRANCA	BRANCA	PARDA	BRANCA	5	branca	ohss8	branca	ry5hf	branca	h8sn9	branca	4opil	branca	bn2y
	BRANCA	PARDA	BRANCA	BRANCA	5	parda	exkvc	parda	j4wqw	branca	8dhwy	branca	9kot7	branca	lgetc
	PRETA	PRETA	PRETA	PARDA	5	parda	ul4q0	preta	i6nl2	preta	vg7oo	parda	cfauw	preta	jc4ta
	PRETA	PRETA	PRETA	PARDA	5	preta	ygvxs	preta	vg7oo	parda	wudg8	preta	qmarn	preta	qmarn
	BRANCA	PARDA	PARDA	PARDA	5	parda	qglwc	parda	exkvc	branca	lgkz9	parda	7qkek	parda	fpfat
	PARDA	PRETA	PARDA	PARDA	5	preta	zpqi2	preta	647ie	preta	yezd0	preta	vg7oo	branca	3vir8
	BRANCA	BRANCA	PARDA	PARDA	5	parda	y4fcx	branca	8uzil	branca	cfauw	parda	uoylg	parda	aaa87

Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	PRETA	PARDA	PARDA	PARDA	5	parda	70b9i	parda	p8ori	parda	niyvy	parda	3vir8	parda	pkjed
	PARDA	PARDA	BRANCA	PARDA	5	parda	bo3cb	branca	veack	parda	8c2no	branca	omtm7	branca	lgetc
	BRANCA	BRANCA	PARDA	PARDA	5	branca	qbwkk	branca	ry5hf	branca	9kot7	branca	pkjed	branca	4lx4m
	BRANCA	PARDA	PARDA	PARDA	5	branca	8uzi1	parda	omtm7	parda	wezr4	branca	7qkek	branca	bnaz2y
	BRANCA	BRANCA	BRANCA	BRANCA	5	branca	y4fcx	branca	zpqj2	branca	2ejsl	branca	qeshq	branca	9kot7
	PRETA	PARDA	PRETA	PARDA	5	parda	647ie	parda	ygvxs	parda	9kot7	parda	4opil	parda	4opil
	PARDA	PARDA	PRETA	PARDA	5	parda	pq0ev	parda	ry5hf	parda	d10h0	parda	4c3sf	preta	aaa87
	PRETA	PRETA	PARDA	PRETA	5	preta	j4wqw	preta	5r0ex	preta	ygvxs	preta	hl1it	preta	3wmi5

Foto	Relatado	Maioria	BRA-RACE	Deepface (VGG)	num_reads	reading1	reading1_id	reading2	reading2_id	reading3	reading3_id	reading4	reading4_id	reading5	reading5_id
	PARDA	PARDA	PARDA	PRETA	5	parda	es2q2	preta	wezr4	parda	t8hqz	preta	fz5pj	parda	4lx4m
	PRETA	PARDA	PARDA	PARDA	5	parda	8dhwy	parda	hl1it	branca	omtm7	branca	4c3sf	branca	uoylg
	PRETA	BRANCA	PARDA	PARDA	5	branca	qcy03	branca	w8pm0	branca	2ejsl	branca	95509	branca	veack
	PRETA	PRETA	PRETA	BRANCA	5	preta	g4ojf	preta	ry5hf	preta	q3iot	preta	7qkek	preta	4lx4m
	PARDA	PARDA	PRETA	PRETA	5	parda	p8ori	parda	0r3bp	parda	jc4ta	parda	zoohc	parda	zoohc
	PARDA	PARDA	PARDA	PARDA	4	parda	hhnv4	branca	veack	parda	53viu	parda	aaa87	-	-
	PARDA	BRANCA	BRANCA	PARDA	5	branca	qcy03	branca	kppvk	parda	3vir8	parda	cfauw	branca	ixjao
	PARDA	BRANCA	BRANCA	PARDA	5	parda	bexwr	branca	g0i8z	branca	lgkz9	branca	8dhwy	parda	3vir8

Foto	Relatado	Maioria	BRA-RACE	Deepface (VGG)	num_reads	reading1	reading1_id	reading2	reading2_id	reading3	reading3_id	reading4	reading4_id	reading5	reading5_id
	PARDA	PARDA	PARDA	PARDA	3	parda	3mcis	parda	ixjao	parda	zoohc	-	-	-	-
	PARDA	BRANCA	PARDA	PARDA	5	branca	p8ori	branca	2ejsl	parda	h8sn9	parda	53viu	parda	niyyz
	PRETA	PARDA	PRETA	PRETA	5	parda	ul4q0	parda	1bm7p	preta	9kot7	preta	8uzil	parda	7qkek
	PRETA	BRANCA	BRANCA	PARDA	5	branca	bt8b2	branca	3wmi5	branca	abqns	branca	aaa87	branca	aaa87
	PRETA	PRETA	PRETA	PARDA	5	preta	p8ori	preta	8d2iu	preta	b2opg	preta	ugt0l	preta	2l9g8
	BRANCA	BRANCA	BRANCA	PARDA	3	branca	hl1it	branca	wudg8	branca	tl1s4y	-	-	-	-
	BRANCA	BRANCA	PARDA	PARDA	5	branca	qcy03	parda	g0i8z	branca	mes7j	parda	95e04	parda	lgkz9
	PARDA	PRETA	PARDA	BRANCA	5	branca	2bl9v	preta	95e04	preta	95e04	parda	8dhwy	parda	3wmi5

Foto	Relatado	Maioria	BRA-RACE	Deepface (VGG)	num_reads	reading1	reading1_id	reading2	reading2_id	reading3	reading3_id	reading4	reading4_id	reading5	reading5_id
	BRANCA	BRANCA	PARDA	BRANCA	3	branca	fz5pj	branca	wudg8	branca	zoohc	-	-	-	-
	PARDA	PARDA	PARDA	PARDA	5	parda	hhnv4	branca	lgkz9	parda	4aelp	parda	imqiy	parda	4opil
	BRANCA	PARDA	PRETA	PARDA	5	parda	aqheh	parda	w8pm0	branca	y3vfl	parda	bexvr	preta	jvy5u
	BRANCA	PARDA	PARDA	PARDA	5	parda	i6nl2	parda	yezd0	parda	lgyye	branca	fdxzo	branca	k3efh
	BRANCA	BRANCA	BRANCA	BRANCA	5	branca	pq0ev	branca	h8sn9	parda	dnr6r	parda	lgetc	parda	k9e5t
	PARDA	PARDA	PARDA	PARDA	5	parda	pq0ev	parda	zt2ih	branca	i6nl2	branca	bo3cb	parda	b2opg
	PRETA	PRETA	PRETA	PRETA	5	parda	p8ori	preta	b2opg	preta	j4wqw	preta	8e85t	preta	dnr6r
	PRETA	PARDA	PRETA	PARDA	5	preta	2ejsl	parda	kppvk	parda	ri9l5	preta	nhybb	parda	3g99e

Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	PARDA	BRANCA	BRANCA	PARDA	4	branca	zpqj2	parda	zoohc	branca	9gimt	branca	aaa87	-	-
	PRETA	PRETA	PRETA	PRETA	5	preta	dzi4l	preta	a2ykd	preta	q3iot	preta	fz5pj	preta	bnaz2y
	BRANCA	BRANCA	PARDA	PARDA	5	parda	70b9i	branca	rw51	branca	rw51	branca	95e04	branca	0r3bp
	PARDA	BRANCA	BRANCA	PARDA	4	parda	p8ori	branca	j4wqw	branca	ri9l5	parda	niyvz	-	-
	PRETA	PRETA	PRETA	PRETA	5	preta	ohss8	preta	ugt0l	preta	hl1it	preta	4opil	preta	omtm7
	PRETA	BRANCA	PRETA	PARDA	5	branca	veack	parda	vg7oo	branca	7sets	parda	ltvq6	parda	wudg8
	PARDA	BRANCA	PARDA	PARDA	5	branca	kppvck	branca	4c3sf	parda	k3efh	parda	3g99e	parda	fulze
	PRETA	PRETA	PRETA	PRETA	5	preta	y4fcx	preta	aqheh	preta	2bl9v	parda	lgkz9	parda	bt8b2

Foto	Relatado	Maioria	BRA-RACE	Deepface (VGG)	num_reads	reading1	reading1_id	reading2	reading2_id	reading3	reading3_id	reading4	reading4_id	reading5	reading5_id
	BRANCA	BRANCA	BRANCA	BRANCA	5	branca	zt2ih	branca	8c2no	branca	vg7oo	branca	jc4ta	branca	m4cl8
	BRANCA	BRANCA	BRANCA	BRANCA	5	branca	zpqj2	branca	u14q0	branca	nhybb	branca	3wmi5	branca	fulze
	PARDA	PARDA	PARDA	PARDA	5	preta	zpqj2	parda	qglwc	parda	7sets	parda	wezr4	parda	3wmi5
	PARDA	PARDA	BRANCA	BRANCA	5	parda	70b9i	branca	zpqj2	parda	rtmyc	branca	kppvk	branca	dzi41
	BRANCA	BRANCA	BRANCA	PARDA	5	branca	1bm7p	parda	i6nl2	branca	bo3cb	branca	lgyye	branca	wezr4
	PRETA	PARDA	PARDA	PRETA	5	parda	qbwkk	preta	84akg	parda	53viu	parda	es2q2	parda	4lx4m
	PRETA	BRANCA	PARDA	PARDA	5	branca	ik0sh	branca	ik0sh	branca	nh6li	parda	647ie	parda	mes7j
	PARDA	PARDA	PARDA	PARDA	3	branca	rw51	parda	q3iot	parda	ixjao	-	-	-	-

Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	PARDA	BRANCA	PARDA	PARDA	5	parda	qeshq	branca	bt8b2	branca	t1s4y	branca	fdxzo	branca	3g99e
	PRETA	PRETA	PRETA	PRETA	5	preta	x1h40	preta	ik0sh	preta	zt2ih	preta	95e04	preta	84akg
	BRANCA	BRANCA	PARDA	BRANCA	4	branca	2pqfz	branca	8e85t	parda	m4cl8	branca	9gimt	-	-
	BRANCA	BRANCA	PARDA	BRANCA	5	branca	ik0sh	branca	i6nl2	branca	2ejsl	branca	lgkz9	branca	nhybb
	PRETA	PRETA	PRETA	PRETA	5	preta	qglwc	preta	b2opg	preta	4c3sf	preta	9gimt	preta	aaa87
	BRANCA	BRANCA	BRANCA	BRANCA	5	branca	pq0ev	branca	zt2ih	branca	g4ojf	branca	jvy5u	branca	647ie
	BRANCA	BRANCA	PARDA	PARDA	5	branca	i6nl2	branca	y3vfl	parda	a2ykd	branca	omtm7	parda	fpfat
	PARDA	PARDA	PARDA	PARDA	5	parda	rtnyc	parda	rtnyc	parda	nh6li	parda	84akg	parda	d10h0

Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	PARDA	PRETA	PRETA	PRETA	5	preta	1bm7p	preta	rtnyc	preta	bo3cb	parda	hnpzb	preta	4opil
	PRETA	PRETA	PRETA	PARDA	5	preta	ry5hf	preta	hhnv4	branca	lgkz9	parda	fz5pj	parda	cnbbn
	PARDA	BRANCA	BRANCA	BRANCA	5	branca	qcy03	branca	y3vfl	branca	s2bzk	branca	exkvc	branca	5r0ex
	PRETA	PRETA	PRETA	PARDA	5	preta	exkvc	preta	8c2no	preta	4lx4m	preta	ht55l	preta	9gimt
	BRANCA	BRANCA	BRANCA	PARDA	5	branca	ugt0l	branca	exkvc	branca	ri9l5	branca	5r0ex	branca	9gimt
	PARDA	BRANCA	BRANCA	BRANCA	5	branca	70b9i	branca	zpqj2	branca	ik0sh	branca	ik0sh	branca	rtnyc
	BRANCA	BRANCA	PARDA	BRANCA	5	branca	g0i8z	branca	h8sn9	branca	4aelp	branca	hl1it	preta	k9e5t
	PRETA	PARDA	PARDA	PARDA	5	parda	4aelp	parda	ri9l5	parda	hl1it	parda	2l9g8	parda	uoylg

Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	PARDA	PARDA	PARDA	PARDA	5	parda	ul14q0	parda	j4wqw	parda	j4wqw	preta	5r0ex	parda	hradj
	PARDA	PARDA	BRANCA	PARDA	3	branca	lgyye	parda	fz5pj	parda	ltvq6	-	-	-	-
	PARDA	BRANCA	PARDA	PARDA	5	branca	3mcis	branca	2ejsl	branca	rtnyc	branca	lgyye	parda	4lx4m
	PRETA	PARDA	PARDA	PARDA	4	parda	yezd0	parda	ugt0l	parda	aaa87	parda	fulzc	-	-
	BRANCA	BRANCA	PARDA	PARDA	5	branca	ohss8	branca	p8ori	branca	1bm7p	branca	exkvc	branca	qtufd
	PRETA	PARDA	PRETA	PARDA	5	parda	ohss8	preta	ry5hf	parda	a2ykd	parda	2l9g8	parda	r017f
	BRANCA	BRANCA	PARDA	PARDA	5	branca	2ejsl	branca	bexwr	branca	y3vfl	branca	g0i8z	branca	mes7j
	PARDA	BRANCA	BRANCA	PARDA	5	branca	ik0sh	parda	84akg	branca	0r3bp	branca	lgyye	branca	cfauw

Foto	Relatado	Maioria	BRA-RACE	Deepface (VGG)	num_reads	reading1	reading1_id	reading2	reading2_id	reading3	reading3_id	reading4	reading4_id	reading5	reading5_id
	PARDA	PARDA	PARDA	PARDA	5	branca	ik0sh	parda	rtnyc	parda	s2bzk	parda	a2ykd	parda	q3iot
	PARDA	BRANCA	BRANCA	BRANCA	5	branca	1bm7p	branca	mes7j	branca	dzi4l	branca	iazxl	branca	zoohc
	PARDA	PARDA	PARDA	PARDA	4	parda	70b9i	parda	aqheh	parda	ht55l	parda	qmarn	-	-
	PRETA	PRETA	PRETA	PARDA	3	preta	lgyye	parda	wudg8	preta	uoylg	-	-	-	-
	BRANCA	BRANCA	PARDA	PARDA	3	branca	q3iot	parda	3wmi5	branca	4lx4m	-	-	-	-
	BRANCA	BRANCA	PARDA	PRETA	5	branca	y3vfl	branca	y3vfl	parda	qglwc	parda	bt8b2	parda	2l9g8
	PRETA	PRETA	PRETA	PRETA	5	preta	pq0ev	preta	ri9l5	preta	vg7oo	preta	es2q2	preta	cfauw
	PRETA	BRANCA	BRANCA	PARDA	5	branca	95e04	branca	ygvxs	parda	3wmi5	branca	iazxl	parda	3g99e

Foto	Relatado	Maioria	BRA-RACE	Deepface (VGG)	num_reads	reading1	reading1_id	reading2	reading2_id	reading3	reading3_id	reading4	reading4_id	reading5	reading5_id
	PRETA	PARDA	PRETA	PARDA	5	branca	w8pm0	parda	8d2iu	parda	kppvk	parda	4opil	parda	t8hqz
	PARDA	PARDA	PARDA	PARDA	5	parda	3mcis	parda	nh6li	parda	95509	parda	imqiy	parda	q3iot
	BRANCA	BRANCA	BRANCA	BRANCA	4	branca	ugt0l	branca	ht55l	branca	t1s4y	branca	uoylg	-	-
	PARDA	PARDA	PARDA	PARDA	4	parda	y3vfl	parda	cfauw	parda	qmarn	parda	9gimt	-	-
	PRETA	PRETA	PRETA	PRETA	5	preta	vlu0v	preta	exkvc	preta	8e85t	preta	nhybb	preta	fpfat
	PARDA	PRETA	PRETA	PARDA	5	preta	bo3cb	preta	rvh5l	preta	95e04	preta	8c2no	parda	k3efh
	PRETA	PRETA	PRETA	PRETA	5	preta	y4fcx	preta	s2bzk	parda	53viu	parda	hradj	parda	qtufd
	PRETA	PRETA	PRETA	PRETA	3	preta	veack	preta	4opil	preta	2l9g8	-	-	-	-

Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	PARDA	PARDA	PARDA	PARDA	5	parda	ugt0l	branca	53viu	parda	4lx4m	parda	m4cl8	parda	fulzc
	PRETA	PARDA	PRETA	PARDA	5	parda	w8pm0	preta	vlu0v	parda	2pqfz	parda	lgkz9	parda	0r3bp
	PARDA	BRANCA	BRANCA	BRANCA	5	branca	s2bzk	branca	0r3bp	branca	9kot7	branca	tl54y	branca	abqns
	PARDA	PARDA	PARDA	PARDA	5	parda	bexwr	parda	ugt0l	parda	8dhwy	parda	es2q2	parda	fz5pj
	BRANCA	BRANCA	BRANCA	PARDA	4	branca	2bl9v	branca	4aelp	branca	qmarn	branca	9gimt	-	-
	BRANCA	BRANCA	BRANCA	BRANCA	5	branca	ohss8	branca	vlu0v	branca	g4ojf	branca	2ejsl	parda	f7mix
	BRANCA	BRANCA	PARDA	PARDA	5	parda	3mcis	branca	qcy03	branca	pq0ev	branca	yezd0	branca	lgkz9
	BRANCA	BRANCA	BRANCA	PARDA	3	branca	jvy5u	branca	imqjy	branca	fpfat	-	-	-	-

Foto	Relatado	Maioria	BRA-RACE	Deepface (VGG)	num_reads	reading1	reading1_id	reading2	reading2_id	reading3	reading3_id	reading4	reading4_id	reading5	reading5_id
	PRETA	PRETA	PRETA	PRETA	5	preta	84akg	preta	ygvxs	preta	qtufd	preta	7sets	preta	3wmi5
	PARDA	BRANCA	BRANCA	PARDA	5	branca	ik0sh	branca	pq0ev	parda	niyvz	parda	4lx4m	parda	bnaz2y
	BRANCA	BRANCA	PARDA	BRANCA	3	branca	rw5h1	branca	lgetc	branca	uoylg	-	-	-	-
	BRANCA	BRANCA	BRANCA	BRANCA	5	branca	qcy03	branca	2bl9v	branca	bo3cb	parda	hhnv4	branca	ltvq6
	PARDA	PARDA	PARDA	PARDA	5	parda	lbn7p	parda	lbn7p	branca	lgkz9	parda	3vir8	branca	cfauw
	PARDA	PARDA	BRANCA	PARDA	5	branca	y4fcx	parda	y3vfl	parda	qglwc	branca	r017f	parda	r017f
	PRETA	PRETA	PRETA	PRETA	5	preta	nh6li	preta	g0i8z	preta	95509	preta	dzi41	preta	8c2no
	PRETA	PRETA	PRETA	PARDA	5	preta	pq0ev	preta	3vir8	parda	cnbbn	parda	jc4ta	parda	jc4ta

Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	BRANCA	BRANCA	BRANCA	PARDA	5	branca	ohss8	branca	vlu0v	branca	8d2iu	branca	g0i8z	branca	kppv/k
	PARDA	PARDA	PARDA	PARDA	3	parda	0r3bp	parda	fz5pj	parda	fdxzo	-	-	-	-
	BRANCA	BRANCA	BRANCA	PARDA	4	branca	84akg	branca	j4wqw	branca	iazxl	branca	cnbbn	-	-
	PARDA	BRANCA	PARDA	BRANCA	5	branca	imqjy	branca	53viu	branca	7sets	parda	3g99e	parda	zoohc
	BRANCA	BRANCA	PARDA	PARDA	5	branca	zpqj2	branca	w8pm0	parda	dnr6r	parda	ixjao	parda	abqns
	BRANCA	PARDA	PARDA	PARDA	5	branca	qbwkk	parda	yezd0	parda	t8hqz	parda	wudg8	branca	4c3sf
	PARDA	PARDA	PARDA	PARDA	5	parda	3mcis	parda	zt2ih	preta	jvy5u	parda	nhybb	parda	niyvz
	PRETA	PARDA	PRETA	PRETA	5	preta	vlu0v	parda	hnhv4	parda	ri9l5	parda	wudg8	parda	k3efh

Foto	Relatado	Maioria	BRA-RACE	Deepface (VGG)	num_reads	reading1	reading1_id	reading2	reading2_id	reading3	reading3_id	reading4	reading4_id	reading5	reading5_id
	PRETA	PRETA	PRETA	PRETA	5	preta	zpqj2	preta	mes7j	parda	53viu	preta	hradj	preta	8e85t
	PARDA	BRANCA	PARDA	BRANCA	5	branca	vlu0v	parda	647ie	branca	kppvk	branca	ugt0l	branca	exkvc
	BRANCA	BRANCA	BRANCA	BRANCA	5	parda	y4fcx	branca	ul4q0	branca	vlu0v	branca	hradj	parda	t8hqz
	BRANCA	BRANCA	PARDA	PARDA	5	parda	zt2ih	branca	nh6li	branca	vg7oo	parda	fpfat	branca	fz5pj
	PARDA	BRANCA	PARDA	BRANCA	5	branca	lbn7p	branca	veack	branca	r017f	branca	ht55l	branca	uoylg
	PARDA	BRANCA	BRANCA	PARDA	3	branca	es2q2	branca	q3iot	branca	fulzc	-	-	-	-
	PRETA	PRETA	PRETA	PRETA	5	preta	s2bzk	preta	pr0ic	preta	wezr4	preta	3vir8	parda	wudg8
	PRETA	PRETA	PRETA	PRETA	5	preta	g4ojf	preta	ygvxs	preta	dnr6r	preta	nhybb	preta	q3iot

Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	PARDA	PARDA	PARDA	PARDA	5	parda	ik0sh	parda	8d2iu	parda	imqjy	parda	pkjed	parda	iazxl
	BRANCA	BRANCA	PARDA	BRANCA	5	parda	vlu0v	branca	1bm7p	branca	2pqfz	parda	4aelp	parda	niyvyz
	PRETA	PARDA	PRETA	PARDA	5	parda	3mcis	parda	8dhwy	parda	wezr4	parda	3wmi5	parda	bnaz2y
	PRETA	PARDA	PARDA	BRANCA	5	parda	bnaz2y	parda	ixjao	parda	ixjao	parda	k3efh	parda	abqns
	PARDA	PARDA	PARDA	PARDA	3	parda	7sets	parda	pkjed	parda	abqns	-	-	-	-
	BRANCA	BRANCA	BRANCA	PARDA	5	branca	y3vfl	branca	exkvc	branca	2l9g8	branca	tl54y	branca	fdxzo
	PARDA	PARDA	PARDA	PARDA	4	parda	j4wqw	parda	lgetc	parda	ht551	parda	abqns	-	-
	PRETA	PRETA	PARDA	PRETA	3	preta	pr0ic	preta	omtm7	parda	3g99e	-	-	-	-


Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	PRETA	PRETA	PRETA	PRETA	5	preta	3mcis	preta	g4ojf	preta	niyvz	preta	pkjed	preta	fz5pj
	BRANCA	PARDA	BRANCA	BRANCA	5	parda	bo3cb	branca	hradj	parda	0r3bp	parda	3vir8	parda	ht551
	PARDA	PARDA	PARDA	PARDA	5	parda	647ie	parda	yezd0	branca	4opil	parda	7qkek	parda	fz5pj
	PRETA	PARDA	PARDA	PARDA	5	parda	x1h40	preta	5r0ex	parda	2l9g8	parda	fpfat	parda	ixjao
	PRETA	PARDA	PRETA	PARDA	5	preta	aqheh	parda	dzi41	parda	lgkz9	parda	9kot7	parda	ltvq6
	PRETA	PARDA	PRETA	PARDA	5	parda	zt2ih	parda	s2bzk	branca	qtufd	parda	iazxl	parda	aaa87
	PARDA	PARDA	BRANCA	BRANCA	5	branca	mes7j	parda	b2opg	parda	cnbbn	parda	m4cl8	parda	qmarn
	BRANCA	PARDA	PARDA	PARDA	4	parda	ri915	parda	9gimt	parda	9gimt	parda	fulze	-	-

Foto	Relatado	Maioria	BRA-RACE	Deepface (VGG)	num_reads	reading1	reading1_id	reading2	reading2_id	reading3	reading3_id	reading4	reading4_id	reading5	reading5_id
	BRANCA	BRANCA	BRANCA	PARDA	5	branca	rtnyc	branca	vg7oo	branca	4lx4m	branca	cnbbn	parda	m4cl8
	PARDA	PARDA	BRANCA	PARDA	5	parda	vlu0v	parda	bexwr	parda	95509	parda	95509	parda	bt8b2
	PARDA	BRANCA	BRANCA	PARDA	5	parda	70b9i	branca	x1h40	branca	qg1wc	branca	2pqfz	parda	8e85t
	BRANCA	BRANCA	BRANCA	BRANCA	5	branca	pr0ic	branca	a2ykd	branca	a2ykd	branca	es2q2	branca	uoylg
	PARDA	PARDA	PARDA	PARDA	5	parda	h8sn9	parda	8e85t	parda	fpfat	parda	jc4ta	parda	jc4ta
	PRETA	PRETA	PRETA	PARDA	5	preta	y4fcx	preta	aqheh	preta	g0i8z	preta	8e85t	preta	fz5pj
	BRANCA	BRANCA	PARDA	PARDA	5	branca	ry5hf	branca	imqjy	parda	ri915	branca	pr0ic	parda	nhybb
	BRANCA	BRANCA	BRANCA	PARDA	5	branca	bo3cb	branca	ugt0l	branca	ygvxs	branca	9kot7	branca	niyvz

Foto	Relatado	Maioria	BRA-RACE	Deepface (VGG)	num_reads	reading1	reading1_id	reading2	reading2_id	reading3	reading3_id	reading4	reading4_id	reading5	reading5_id
	PRETA	PARDA	PARDA	PARDA	5	preta	y3vfl	parda	h8sn9	parda	vg7oo	parda	tl54y	parda	ixjao
	BRANCA	BRANCA	BRANCA	BRANCA	5	parda	x1h40	branca	kppvk	branca	omtm7	branca	omtm7	branca	omtm7
	BRANCA	BRANCA	PARDA	PARDA	5	branca	qcy03	parda	exkvc	branca	8c2no	branca	pr0ic	branca	k9e5t
	BRANCA	BRANCA	PARDA	BRANCA	5	branca	pq0ev	branca	ry5hf	parda	9kot7	branca	lgetc	branca	7qkek
	BRANCA	BRANCA	BRANCA	BRANCA	5	parda	g4ojf	branca	ry5hf	branca	hhnv4	branca	veack	branca	qeshq
	PARDA	PARDA	PARDA	PARDA	5	parda	rtnyc	parda	omtm7	parda	t8hqz	parda	d10h0	parda	r017f
	PRETA	PRETA	PRETA	PRETA	5	preta	i6nl2	preta	kppvk	preta	pr0ic	preta	q3iot	parda	ltvq6
	PARDA	BRANCA	BRANCA	PARDA	5	branca	zt2ih	branca	1bm7p	branca	hhnv4	parda	5r0ex	branca	pkjed

Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	BRANCA	BRANCA	PARDA	BRANCA	5	branca	70b9i	branca	w8pm0	branca	ugt0l	branca	dnr6r	branca	es2q2
	BRANCA	BRANCA	BRANCA	PARDA	5	branca	w8pm0	branca	rtnyc	branca	hradj	branca	8c2no	parda	wezr4
	BRANCA	PARDA	PARDA	PARDA	5	parda	qcy03	parda	h8sn9	parda	hradj	parda	omtm7	parda	pkjed
	PRETA	PRETA	PRETA	PRETA	5	preta	x1h40	preta	pq0ev	preta	ea0js	preta	g0i8z	preta	4c3sf
	PRETA	PRETA	PRETA	PRETA	5	preta	b2opg	preta	2pqfz	preta	hradj	preta	bt8b2	parda	es2q2
	BRANCA	BRANCA	PARDA	BRANCA	5	branca	w8pm0	branca	bexwr	branca	dnr6r	branca	t8hqz	branca	ltvq6
	PRETA	PRETA	PRETA	PRETA	5	preta	84akg	preta	qg1wc	preta	hhnv4	preta	lgkz9	preta	8e5t
	PRETA	PARDA	PRETA	PRETA	5	parda	95509	parda	veack	preta	niy vz	parda	jc4ta	parda	jc4ta

Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	BRANCA	BRANCA	BRANCA	BRANCA	5	branca	zpqj2	branca	g0i8z	branca	wudg8	branca	ht551	branca	fulzc
	PARDA	PARDA	PARDA	PARDA	5	branca	3mcis	parda	647ie	parda	95e04	parda	ltvq6	preta	iazxl
	PRETA	PRETA	PRETA	PRETA	5	preta	2ejsl	preta	dzi4l	preta	dzi4l	preta	hradj	preta	8e85t
	PARDA	BRANCA	BRANCA	PARDA	5	branca	70b9i	branca	2bl9v	parda	mes7j	parda	hhnv4	parda	53viu
	BRANCA	BRANCA	PARDA	BRANCA	5	branca	dnr6r	branca	k9e5t	branca	jc4ta	branca	ht551	branca	abqns
	PARDA	PARDA	PARDA	PRETA	5	parda	aqheh	parda	veack	parda	es2q2	parda	d10h0	parda	cfauw
	PRETA	PARDA	PARDA	PARDA	5	preta	jvy5u	parda	bo3cb	parda	rvh5l	preta	b2opg	parda	lgkz9
	BRANCA	BRANCA	PARDA	PARDA	4	branca	ygvxs	branca	nivyvz	branca	jc4ta	branca	wudg8	-	-

Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	PARDA	PARDA	PARDA	PARDA	5	parda	x1h40	parda	h8sn9	preta	8uzil	parda	wezr4	parda	bnaz2y
	PRETA	PRETA	PRETA	PARDA	4	preta	vlu0v	preta	qg1wc	preta	bt8b2	preta	bt8b2	-	-
	PRETA	PRETA	PRETA	PRETA	5	preta	s2bzk	preta	95509	preta	9kot7	preta	pr0ic	preta	3wmi5
	PRETA	BRANCA	PARDA	PARDA	5	branca	jvy5u	branca	lgyye	parda	ygvxs	parda	nhybb	parda	iazxl
	PRETA	PRETA	PRETA	PARDA	3	preta	ygvxs	preta	fdxzo	preta	4c3sf	-	-	-	-
	BRANCA	BRANCA	BRANCA	BRANCA	5	branca	i6nl2	branca	bexwr	parda	pkjed	parda	cnbbn	branca	cfauw
	PRETA	BRANCA	PARDA	PARDA	5	branca	y4fcx	branca	bexwr	parda	yezd0	parda	j4wqw	parda	r017f
	PRETA	PARDA	PARDA	PARDA	5	parda	ul4q0	preta	k9e5t	parda	ltvq6	parda	k3efh	preta	fulze

Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	PRETA	PRETA	PRETA	PRETA	4	preta	bo3cb	preta	8uzi1	preta	d10h0	preta	pkjed	-	-
	PARDA	PARDA	PARDA	PARDA	5	parda	bt8b2	parda	ltvq6	branca	4c3sf	parda	3g99e	parda	zoohc
	PARDA	PARDA	PRETA	PARDA	5	branca	ohss8	parda	zt2ih	parda	g0i8z	parda	yezd0	parda	lgyye
	PRETA	PRETA	PRETA	PRETA	5	preta	70b9i	preta	p8ori	preta	hl1it	preta	t8hqz	preta	cnbbn
	PARDA	PARDA	PARDA	PARDA	5	parda	s2bzk	branca	hradj	parda	8c2no	parda	nhybb	parda	4lx4m
	BRANCA	BRANCA	BRANCA	BRANCA	5	branca	p8ori	branca	h8sn9	branca	qg1wc	branca	yezd0	branca	5r0ex
	PRETA	PRETA	PRETA	PRETA	5	preta	70b9i	preta	95509	parda	dzi41	parda	4aelp	parda	wezr4
	BRANCA	PARDA	PARDA	PARDA	6	parda	ohss8	preta	95509	parda	0r3bp	parda	es2q2	parda	219g8

Foto	Relatado	Maioria	BRA-RACE	Deepface (VGG)	num_reads	reading1	reading1_id	reading2	reading2_id	reading3	reading3_id	reading4	reading4_id	reading5	reading5_id
	PARDA	PARDA	PARDA	PARDA	5	parda	qglwc	parda	bnay	branca	cfauw	branca	ixjao	parda	qmarn
	PRETA	PRETA	PRETA	PARDA	5	preta	qcy03	preta	2bl9v	preta	hhnv4	preta	0r3bp	preta	a2ykd
	PRETA	PARDA	PARDA	PARDA	5	parda	aqheh	parda	w8pm0	parda	95e04	parda	8dhwy	parda	7qkek
	PARDA	PRETA	PRETA	PRETA	5	preta	ul4q0	preta	xlh40	preta	vlu0v	parda	ygvxs	preta	3vir8
	BRANCA	PARDA	BRANCA	BRANCA	5	parda	rtnyc	parda	647ie	preta	95509	parda	ugt0l	branca	qtufd
	BRANCA	BRANCA	BRANCA	BRANCA	5	branca	xlh40	branca	bexwr	branca	nh6li	parda	qglwc	branca	j4wqw
	PARDA	PRETA	PRETA	PARDA	4	preta	zpqj2	preta	g0i8z	parda	r017f	parda	zoohc	-	-
	PRETA	PARDA	PRETA	PARDA	3	preta	2bl9v	parda	lgetc	parda	uoylg	-	-	-	-

Foto	Relatado	Maioria	BRA-RACE	Deepface (VGG)	num_reads	reading1	reading1_id	reading2	reading2_id	reading3	reading3_id	reading4	reading4_id	reading5	reading5_id
	PRETA	BRANCA	BRANCA	PARDA	3	branca	es2q2	branca	t8hqz	branca	k3efh	-	-	-	-
	PARDA	PRETA	PRETA	PRETA	5	preta	kppvck	preta	lgyye	preta	ygvxs	preta	dnr6r	preta	pr0ic
	PRETA	PARDA	PRETA	PRETA	5	preta	pq0ev	parda	g4ojf	parda	2pqfz	parda	hhnv4	parda	qeshq
	BRANCA	BRANCA	BRANCA	BRANCA	5	branca	95e04	branca	dzi4l	branca	hradj	branca	lgetc	branca	4lx4m
	PARDA	PARDA	PARDA	PARDA	5	branca	ohss8	parda	u14q0	parda	8dhwy	parda	cnbbn	parda	t1s4y
	PARDA	PARDA	PRETA	PARDA	5	preta	aqheh	parda	8d2iu	parda	g0i8z	parda	veack	preta	9kot7
	BRANCA	BRANCA	PARDA	BRANCA	5	branca	w8pm0	branca	qeshq	branca	ri915	branca	7sets	branca	pr0ic
	PRETA	PRETA	None	BRANCA	5	preta	pq0ev	preta	8d2iu	preta	b2opg	preta	veack	preta	j4wqw

Foto	Relatado	Maioria	BRA-RACE	Deepface (VGG)	num_reads	reading1	reading1_id	reading2	reading2_id	reading3	reading3_id	reading4	reading4_id	reading5	reading5_id
	PRETA	BRANCA	PARDA	PARDA	5	branca	s2bzk	branca	nhybb	parda	2l9g8	branca	d10h0	parda	iazxl
	PRETA	PRETA	PRETA	PRETA	5	preta	zt2ih	preta	647ie	preta	t8hqz	preta	k9e5t	preta	iazxl
	PRETA	PRETA	PRETA	PARDA	5	preta	bexwr	preta	mes7j	parda	veack	parda	9kot7	parda	k3efh
	BRANCA	BRANCA	BRANCA	BRANCA	5	branca	95e04	branca	4aelp	branca	8dhwy	branca	7sets	branca	8uzil
	PRETA	BRANCA	PRETA	PARDA	5	branca	ohss8	branca	4opil	parda	r017f	parda	wudg8	parda	m4cl8
	PRETA	PARDA	PARDA	PARDA	5	parda	70b9i	parda	ugt0l	parda	nhybb	parda	omtm7	parda	3wmi5
	BRANCA	BRANCA	BRANCA	PARDA	5	branca	1bm7p	parda	bexwr	branca	jvy5u	parda	exkvc	branca	qtufd
	PRETA	PRETA	None	BRANCA	3	preta	y4fcx	preta	xlh40	preta	aaa87	-	-	-	-

Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	PRETA	PARDA	PRETA	PARDA	3	parda	iaxl	parda	iaxl	parda	m4cl8	-	-	-	-
	PRETA	PRETA	PRETA	PRETA	5	preta	qbwkk	preta	bt8b2	parda	lgetc	parda	m4cl8	parda	fdxzo
	PARDA	BRANCA	PARDA	PARDA	3	branca	2pqfz	branca	8c2no	parda	abqns	-	-	-	-
	BRANCA	PARDA	PARDA	PARDA	5	parda	70b9i	parda	4c3sf	parda	zoohc	parda	aaa87	parda	aaa87
	BRANCA	PARDA	PARDA	PARDA	5	parda	3mcis	parda	bexwr	parda	s2bzk	parda	ygvxs	parda	2l9g8
	PARDA	BRANCA	PRETA	PARDA	5	branca	i6nl2	branca	rtnyc	branca	mes7j	parda	ixjao	parda	abqns
	BRANCA	BRANCA	BRANCA	PARDA	5	branca	zt2ih	branca	rvh51	branca	s2bzk	branca	2pqfz	branca	lgkz9
	PARDA	PARDA	PARDA	PARDA	5	branca	kppvk	parda	dnr6r	parda	9kot7	parda	7qkek	parda	fpmat

Foto	Relatado	Maioria	BRA-RACE	Deepface (VGG)	num_reads	reading1	reading1_id	reading2	reading2_id	reading3	reading3_id	reading4	reading4_id	reading5	reading5_id
	BRANCA	BRANCA	PARDA	BRANCA	5	branca	qcy03	branca	imqjy	parda	es2q2	parda	bn2y	parda	fdxzo
	BRANCA	BRANCA	PARDA	BRANCA	5	branca	qglwc	branca	pr0ic	parda	wexr4	branca	t8hqz	parda	ht551
	PRETA	PRETA	None	BRANCA	5	preta	aqheh	preta	qbwkk	preta	rwh51	preta	s2bzk	preta	hnhv4
	PRETA	PARDA	PRETA	PRETA	5	parda	8e85t	parda	tl54y	parda	k3efh	parda	k3efh	preta	fulzc
	PARDA	PARDA	PARDA	PARDA	3	preta	qcy03	parda	bn2y	parda	zoohc	-	-	-	-
	PRETA	PRETA	PARDA	PARDA	5	preta	95509	parda	j4wqw	preta	ri915	preta	8dhwy	preta	vg700
	PRETA	PARDA	PARDA	PARDA	5	preta	y4fcx	parda	y3vfl	parda	yezd0	parda	dzi41	parda	a2ykd
	PRETA	PARDA	PARDA	PARDA	5	parda	qbwkk	parda	hnhv4	parda	dzi41	parda	exkvc	parda	219c8

Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	BRANCA	PARDA	PARDA	PARDA	5	parda	ohss8	parda	pq0ev	parda	qtufd	parda	4opil	branca	7sets
	PARDA	PARDA	PARDA	BRANCA	5	parda	zt2ih	parda	84akg	parda	b2opg	preta	2pqfz	parda	imqiy
	PARDA	PARDA	PRETA	PARDA	5	parda	y4fcx	preta	jvy5u	parda	qtufd	parda	lgetc	parda	d10h0
	BRANCA	BRANCA	PARDA	PARDA	5	branca	zpqj2	branca	w8pm0	branca	vlu0v	branca	y3vfl	branca	yezd0
	PRETA	PRETA	PRETA	PRETA	5	preta	i6nl2	preta	exkvc	preta	r017f	preta	fpfat	parda	tl s4y
	BRANCA	BRANCA	PARDA	BRANCA	5	branca	2ejsl	branca	q3iot	parda	k9e5t	parda	r017f	parda	fz5pj
	BRANCA	BRANCA	BRANCA	BRANCA	5	branca	y4fcx	branca	1bm7p	branca	2ejsl	parda	a2ykd	parda	d10h0
	PRETA	PRETA	PRETA	PRETA	5	preta	h8sn9	preta	95e04	preta	8e85t	preta	a2ykd	preta	tl s4y

Foto	Relatado	Maioria	BRA-RACE	Deepface (VGG)	num_reads	reading1	reading1_id	reading2	reading2_id	reading3	reading3_id	reading4	reading4_id	reading5	reading5_id
	PARDA	BRANCA	BRANCA	PARDA	5	branca	rwh51	branca	yezd0	parda	veack	branca	ri915	branca	pkjed
	PRETA	PARDA	PRETA	PARDA	5	parda	x1h40	parda	8c2no	parda	7sets	parda	k9e5t	parda	pkjed
	BRANCA	BRANCA	None	BRANCA	4	branca	2ejsl	branca	647ie	branca	veack	parda	2l9g8	-	-
	PRETA	PRETA	PRETA	PRETA	5	preta	x1h40	preta	95509	preta	k9e5t	preta	r017f	parda	k3efh
	PARDA	PARDA	PARDA	PARDA	5	parda	3mcis	parda	2pqfz	parda	qeshq	parda	lgyye	parda	fz5pj
	PRETA	PRETA	PRETA	PARDA	5	preta	aqheh	preta	4aelp	preta	4opil	preta	2l9g8	preta	r017f
	BRANCA	BRANCA	BRANCA	PARDA	5	branca	x1h40	branca	0r3bp	branca	d10h0	branca	cnbnn	branca	k3efh
	PARDA	PRETA	PARDA	PRETA	5	preta	2ejsl	preta	hllit	parda	8uzil	preta	pr0ic	parda	t8hqz

Foto	Relatado	Maioria	BRA-RACE	Deepface (VGG)	num_reads	reading1	reading1_id	reading2	reading2_id	reading3	reading3_id	reading4	reading4_id	reading5	reading5_id
	BRANCA	BRANCA	PARDA	BRANCA	5	branca	p8ori	branca	8c2no	branca	7sets	branca	omtm7	parda	3g99e
	PRETA	PRETA	PRETA	PARDA	5	parda	ik0sh	preta	g4ojf	preta	mes7j	preta	s2bzk	parda	imqiy
	PRETA	PRETA	PRETA	PARDA	5	preta	2ejsl	preta	0r3bp	preta	hl1it	preta	bt8b2	preta	4c3sf
	PARDA	PARDA	PRETA	PARDA	4	preta	jvy5u	parda	b2opg	parda	qeshq	parda	cfauw	-	-
	PRETA	PARDA	PARDA	PARDA	5	parda	zt2ih	parda	g4ojf	parda	qbwkk	parda	2pqfz	branca	kppvk
	PARDA	PARDA	PRETA	PARDA	5	parda	aqheh	preta	8c2no	parda	q3iot	parda	wudg8	parda	zoohc
	PRETA	PRETA	PRETA	PRETA	5	preta	53viu	preta	8dhwy	preta	bt8b2	preta	8uzil	preta	pkjed
	BRANCA	BRANCA	PARDA	PARDA	4	branca	dnr6r	branca	q3iot	branca	9gimt	branca	uoylg	-	-

Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	BRANCA	BRANCA	BRANCA	PARDA	3	branca	cfauw	branca	fdxzo	branca	ixjao	-	-	-	-
	PRETA	PRETA	PRETA	PRETA	5	preta	qbwkk	preta	g0i8z	preta	8uzil	preta	q3iot	preta	iazxl
	PARDA	PARDA	BRANCA	PARDA	5	branca	ik0sh	parda	pq0ev	parda	qtufd	parda	cnbbn	parda	m4cl8
	PARDA	PARDA	PARDA	PARDA	4	parda	7sets	parda	r017f	parda	wudg8	parda	3g99e	-	-
	BRANCA	BRANCA	BRANCA	PARDA	5	branca	w8pm0	branca	2bl9v	branca	84akg	branca	8uzil	parda	9gimt
	BRANCA	BRANCA	BRANCA	BRANCA	3	branca	jvy5u	parda	ry5hf	branca	uoylg	-	-	-	-
	PARDA	PRETA	PRETA	PARDA	5	preta	ea0js	preta	2bl9v	parda	2pqfz	parda	qeshq	preta	5r0ex
	PRETA	PRETA	PRETA	PARDA	5	preta	3mcis	preta	qcy03	preta	8d2iu	preta	hradj	parda	m4cl8

Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	BRANCA	PARDA	PARDA	BRANCA	5	branca	mes7j	parda	s2bzk	parda	t1s4y	parda	3g99e	parda	3g99e
	PARDA	PARDA	PARDA	PARDA	4	preta	2bl9v	parda	b2opg	parda	qeshq	parda	iazxl	-	-
	PARDA	PARDA	PARDA	PARDA	5	parda	i6nl2	branca	9kot7	parda	r017f	parda	wudg8	parda	qmam
	PRETA	PARDA	PARDA	PRETA	5	parda	qbwkk	parda	qglwc	parda	53viu	preta	8c2no	preta	fulze
	PARDA	BRANCA	BRANCA	PARDA	5	branca	g4ojf	branca	a2ykd	parda	niy vz	parda	wezr4	branca	ltvq6
	PRETA	BRANCA	PRETA	PARDA	5	parda	3mcis	preta	y4fcx	branca	u14q0	parda	vlu0v	preta	nh6li
	BRANCA	PARDA	PARDA	PARDA	5	parda	pq0ev	branca	jvy5u	parda	hl1it	parda	a2ykd	parda	wezr4
	BRANCA	PARDA	BRANCA	BRANCA	5	parda	2bl9v	parda	h8sn9	parda	53viu	parda	cnbbn	parda	jc4ta

Foto	Relatado	Maioria	BRA-RACE	Deepface (VGG)	num_reads	reading1	reading1_id	reading2	reading2_id	reading3	reading3_id	reading4	reading4_id	reading5	reading5_id
	BRANCA	BRANCA	BRANCA	PARDA	3	branca	es2q2	branca	es2q2	branca	qmarn	-	-	-	-
	PARDA	PARDA	PARDA	PARDA	5	parda	g4ojf	parda	ry5hf	parda	4aelp	parda	9kot7	parda	7qkek
	PARDA	PARDA	PARDA	PRETA	5	branca	bo3cb	parda	84akg	parda	exkvc	parda	qtufd	parda	k9e5t
	BRANCA	PARDA	PARDA	PARDA	5	parda	84akg	parda	ri9l5	parda	lgyye	parda	4opil	parda	bnaz2y
	PRETA	PRETA	PRETA	PRETA	5	preta	3mcis	preta	j4wqw	preta	3vir8	parda	pkjed	parda	zoohc
	BRANCA	PARDA	BRANCA	PARDA	5	parda	2bl9v	parda	2bl9v	parda	647ie	branca	dzi4l	parda	d10h0
	BRANCA	BRANCA	PARDA	BRANCA	5	parda	xzvny	branca	imqjy	branca	dnr6r	parda	2l9g8	parda	4lx4m
	PARDA	PARDA	PARDA	PARDA	4	parda	p8ori	parda	m4cl8	parda	tl54y	preta	fulzc	-	-

Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	PARDA	PARDA	PARDA	PARDA	5	parda	bt8b2	parda	k9e5t	parda	4lx4m	parda	ht551	parda	3g99e
	BRANCA	BRANCA	PARDA	PARDA	5	branca	jvy5u	parda	nh6li	branca	hl1it	branca	pr0ic	branca	7qkek
	PRETA	PARDA	PRETA	PRETA	5	preta	y4fcx	parda	d10h0	parda	fpfat	preta	4c3sf	parda	qmam
	PRETA	PARDA	PRETA	PARDA	5	parda	lbn7p	preta	2b19v	parda	8dhwy	parda	8c2no	parda	7sets
	BRANCA	BRANCA	BRANCA	BRANCA	5	branca	yezd0	branca	dzi41	branca	7sets	parda	t8hqz	branca	lgetc
	BRANCA	PARDA	PARDA	PARDA	4	parda	ri915	parda	wezr4	parda	t1s4y	parda	ht551	-	-
	BRANCA	BRANCA	BRANCA	PARDA	5	branca	aqheh	branca	nhybb	parda	bn2y	parda	ht551	parda	3g99e
	PARDA	PARDA	BRANCA	PARDA	5	parda	g4ojf	branca	qeshq	parda	niyvz	parda	fdxzo	parda	4c3sf

Foto	Relatado	Maioria	BRA-RACE	Deepface (VGG)	num_reads	reading1	reading1_id	reading2	reading2_id	reading3	reading3_id	reading4	reading4_id	reading5	reading5_id
	BRANCA	BRANCA	BRANCA	PARDA	5	branca	bexwr	branca	rtnyc	branca	lgkz9	branca	lgyye	branca	lgyye
	PRETA	PRETA	PRETA	PARDA	5	preta	b2opg	preta	bnaz2y	preta	9gimt	preta	fulzc	preta	fulzc
	PARDA	PARDA	PARDA	PARDA	4	branca	rw'h51	parda	mes7j	parda	8e85t	parda	fdxzo	-	-
	PARDA	BRANCA	BRANCA	PARDA	5	branca	qbwkk	branca	ry5hf	parda	qeshq	branca	a2ykd	branca	jc4ta
	BRANCA	BRANCA	BRANCA	BRANCA	5	branca	zpqj2	branca	ry5hf	branca	3wmi5	branca	m4cl8	branca	fdxzo
	PARDA	PARDA	PARDA	PARDA	5	parda	h8sn9	parda	yezd0	parda	8e85t	branca	bt8b2	parda	a2ykd
	BRANCA	PARDA	PARDA	PARDA	4	parda	k9e5t	parda	ixjao	parda	3g99e	parda	9gimt	-	-
	PRETA	PRETA	PRETA	PRETA	5	preta	zpqj2	preta	g4ojf	parda	nhybb	preta	cfauw	preta	9gimt

Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	PRETA	PRETA	PRETA	PRETA	5	preta	qcy03	preta	ul4q0	preta	nh6li	preta	qeshq	preta	vg7oo
	BRANCA	BRANCA	BRANCA	BRANCA	5	branca	qeshq	branca	cfauw	parda	fdxzo	branca	3g99e	branca	abqns
	PARDA	BRANCA	PARDA	PARDA	5	branca	3mcis	parda	ul4q0	branca	p8ori	branca	w8pm0	parda	kppvk
	BRANCA	BRANCA	PARDA	PARDA	5	preta	y4fcx	branca	aqheh	branca	qbwkk	branca	hradj	branca	k9e5t
	BRANCA	PARDA	PARDA	PARDA	5	branca	ul4q0	parda	t8hqz	parda	jc4ta	parda	abqns	branca	aaa87
	BRANCA	BRANCA	PARDA	BRANCA	5	branca	53viu	parda	niy vz	branca	fdxzo	branca	4c3sf	branca	aaa87
	BRANCA	BRANCA	PARDA	BRANCA	5	branca	h8sn9	branca	4aelp	branca	5r0ex	branca	pr0ic	branca	wezr4
	PRETA	PRETA	PRETA	PRETA	5	preta	ohss8	preta	bexwr	parda	qbwkk	parda	7qkek	preta	cfauw

Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	BRANCA	PARDA	PARDA	BRANCA	5	branca	p8ori	parda	95e04	parda	4aelp	branca	lgetc	branca	7qkek
	PRETA	PRETA	PRETA	PRETA	5	preta	2ejsl	preta	rtnyc	preta	rw51	parda	ltvq6	parda	abqns
	BRANCA	BRANCA	BRANCA	PARDA	5	branca	70b9i	branca	p8ori	parda	zt2ih	branca	jvy5u	parda	ry5hf
	BRANCA	BRANCA	PARDA	PARDA	5	branca	y3vfl	branca	84akg	branca	lgyye	branca	qtufd	parda	bn2y
	PARDA	PARDA	PARDA	PARDA	5	parda	vlu0v	parda	s2bzk	parda	omtm7	parda	m4cl8	parda	uoylg
	PRETA	PRETA	PRETA	PRETA	5	parda	qbwkk	preta	647ie	preta	95509	preta	5r0ex	preta	q3iot
	PARDA	PARDA	PRETA	PARDA	5	parda	w8pm0	preta	5r0ex	parda	ygvxs	parda	qtufd	parda	7qkek
	PRETA	PRETA	PRETA	PARDA	3	preta	5r0ex	preta	5r0ex	preta	3vir8	-	-	-	-

Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	BRANCA	PARDA	PARDA	PARDA	5	parda	rw51	preta	8uzi1	parda	lgetc	preta	ht551	parda	tl54y
	PARDA	PARDA	PARDA	PARDA	5	parda	3mcis	parda	zt2ih	parda	8dhwy	parda	vg7oo	parda	d10h0
	PARDA	PARDA	BRANCA	PARDA	4	parda	vlu0v	parda	vg7oo	branca	nhybb	parda	fulzc	-	-
	PRETA	PARDA	PRETA	PRETA	5	parda	nh6li	parda	rw51	preta	mes7j	preta	95e04	preta	b2opg
	PRETA	PRETA	PRETA	PARDA	5	preta	w8pm0	parda	nh6li	preta	84akg	preta	dnr6r	preta	wezr4
	BRANCA	BRANCA	BRANCA	PARDA	5	parda	ik0sh	branca	53viu	branca	ri915	branca	hradj	branca	5r0ex
	PARDA	PARDA	PRETA	PARDA	5	preta	i6nl2	parda	2pqfz	parda	kppvkc	parda	imqjy	parda	hl1it
	PARDA	PARDA	PRETA	PRETA	5	parda	p8ori	parda	1bm7p	preta	7sets	preta	pr0ic	parda	t8hqz

Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	BRANCA	PARDA	BRANCA	BRANCA	5	parda	qeshq	parda	0r3bp	parda	lgetc	parda	cnbbn	parda	ht551
	PARDA	BRANCA	BRANCA	PARDA	5	branca	70b9i	branca	g0i8z	branca	8uzi1	branca	k9e5t	branca	iazxl
	PRETA	PRETA	None	BRANCA	5	parda	aqheh	preta	qbwkk	preta	2pqfz	preta	95509	parda	8dhwy
	BRANCA	PARDA	PARDA	BRANCA	5	parda	ohss8	branca	nh6li	parda	95e04	branca	ugt0l	parda	4aelp
	PARDA	BRANCA	PARDA	PARDA	5	parda	rw'h51	branca	imqjy	branca	h11it	branca	8uzi1	branca	k3efh
	PRETA	PRETA	PRETA	PRETA	4	preta	qcy03	preta	rtnyc	preta	84akg	preta	zoohc	-	-
	PRETA	PARDA	PRETA	PARDA	5	parda	y3vfl	branca	jvy5u	parda	bo3cb	parda	bo3cb	parda	qbwkk
	PRETA	PRETA	PRETA	PARDA	5	parda	qcy03	preta	ik0sh	preta	g4oif	preta	bexwr	preta	nhybb

Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	PARDA	BRANCA	BRANCA	BRANCA	5	branca	aqheh	parda	yezd0	branca	4aelp	parda	3wmi5	parda	bnaz2y
	BRANCA	BRANCA	PARDA	BRANCA	5	branca	1bm7p	branca	0r3bp	branca	5r0ex	branca	ltvq6	branca	m4cl8
	BRANCA	PARDA	BRANCA	PARDA	5	parda	647ie	parda	ry5hf	parda	b2opg	parda	hhnv4	parda	imqjy
	PRETA	PRETA	PRETA	PRETA	5	preta	x1h40	preta	647ie	preta	mes7j	preta	imqjy	preta	k9e5t
	PARDA	PARDA	PARDA	PARDA	5	parda	veack	parda	53viu	parda	qtufd	parda	cnbbn	parda	abqns
	PARDA	BRANCA	PRETA	PARDA	5	branca	nh6li	branca	95509	parda	4aelp	parda	53viu	parda	vg7oo
	PARDA	PARDA	PARDA	PARDA	3	parda	y3vfl	parda	ugt0l	parda	dnr6r	-	-	-	-
	PRETA	PRETA	PRETA	PRETA	5	preta	rwh5l	preta	mes7j	preta	84akg	preta	qeshq	preta	qtufd

Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	PARDA	PRETA	PARDA	PARDA	5	preta	imqjy	preta	8c2no	parda	dnr6r	parda	es2q2	parda	4lx4m
	BRANCA	PARDA	BRANCA	PARDA	4	parda	x1h40	parda	3wmi5	branca	3vir8	parda	qmarn	-	-
	PRETA	PRETA	PRETA	PRETA	5	preta	ul4q0	parda	8dhwy	preta	8uzi1	preta	niyvz	preta	iazxl
	PARDA	BRANCA	PRETA	PARDA	5	parda	2b19v	branca	qglwc	branca	dzi41	branca	8e85t	branca	ixjao
	PARDA	PARDA	BRANCA	PARDA	5	branca	ohss8	parda	ul4q0	parda	7qkek	branca	pkjed	parda	ixjao
	PARDA	PARDA	PARDA	PARDA	5	parda	bo3cb	parda	bt8b2	branca	pr0ic	parda	fpfat	parda	qmarn
	BRANCA	PARDA	BRANCA	BRANCA	3	parda	a2ykd	parda	t8hqz	parda	fpfat	-	-	-	-
	BRANCA	BRANCA	PARDA	BRANCA	3	branca	hradj	branca	qmarn	branca	zoohc	-	-	-	-

Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	BRANCA	BRANCA	BRANCA	PARDA	5	branca	h8sn9	branca	h8sn9	branca	dzi41	branca	ri915	branca	3vir8
	BRANCA	BRANCA	BRANCA	PARDA	5	branca	g4ojf	parda	2pqfz	branca	qtufd	branca	4opil	parda	3wmi5
	PARDA	BRANCA	PARDA	PARDA	5	branca	nh6li	parda	7sets	branca	pkjed	parda	ixjao	parda	k3efh
	PARDA	PARDA	PARDA	PARDA	5	parda	bo3cb	parda	j4wqw	parda	4aelp	parda	0r3bp	parda	0r3bp
	BRANCA	BRANCA	BRANCA	PARDA	5	branca	qglwc	branca	fpfat	branca	m4cl8	branca	tls4y	branca	qmarn
	PARDA	BRANCA	PARDA	PARDA	5	branca	ul4q0	branca	lgyye	branca	niyvz	branca	jc4ta	branca	aaa87
	BRANCA	BRANCA	BRANCA	PARDA	5	branca	ik0sh	branca	8uzil	branca	3vir8	branca	d10h0	branca	d10h0
	BRANCA	PARDA	PARDA	PARDA	4	parda	r017f	parda	fz5pj	parda	ht551	parda	k3efh	-	-

Foto	Relatado	Maioria	BRA- RACE	Deepface (VGG)	num_read s	reading1	reading1_ id	reading2	reading2_ id	reading3	reading3_ id	reading4	reading4_ id	reading5	reading5_ id
	PARDA	PARDA	PARDA	PARDA	5	branca	g0i8z	parda	ygvxs	parda	wudg8	parda	fdxzo	parda	4c3sf
	PARDA	PARDA	PARDA	PARDA	3	parda	fdxzo	parda	uoylg	parda	uoylg	-	-	-	-
	PARDA	PARDA	PARDA	BRANCA	5	branca	647ie	parda	b2opg	parda	exkvc	branca	7qkek	branca	fpiat
	BRANCA	BRANCA	PARDA	PARDA	5	branca	jvy5u	branca	hl1it	branca	hl1it	branca	ltvq6	branca	cnbbn
	BRANCA	PARDA	BRANCA	PARDA	5	parda	hhnv4	branca	vg7oo	parda	3vir8	parda	qmarn	parda	abqns