



**UNIVERSIDADE FEDERAL DO TOCANTINS
CÂMPUS UNIVERSITÁRIO DE PALMAS
CURSO DE CIÊNCIA DA COMPUTAÇÃO**

HUMBERTO MARTINS MENDONÇA DUARTE

**VIÉS RACIAL EM ALGORITMOS DE RECONHECIMENTO FACIAL POR
HISTOGRAMAS DE GRADIENTES ORIENTADOS**

PALMAS (TO)

2022

HUMBERTO MARTINS MENDONÇA DUARTE

VIÉS RACIAL EM ALGORITMOS DE RECONHECIMENTO FACIAL POR
HISTOGRAMAS DE GRADIENTES ORIENTADOS

Trabalho de Conclusão de Curso II apresentado à
Universidade Federal do Tocantins para obtenção
do título de Bacharel em Ciência da Computação,
sob a orientação do(a) Prof.(a)
Juliana Leitão Dutra.

Orientador:
Juliana Leitão Dutra

PALMAS (TO)
2022

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da Universidade Federal do Tocantins

D812v Duarte, Humberto Martins Mendonça.
Viés Racial em Algoritmos de Reconhecimento Facial por
Histogramas de Gradientes Orientados. / Humberto Martins Mendonça
Duarte. – Palmas, TO, 2022.
69 f.

Monografia Graduação - Universidade Federal do Tocantins –
Câmpus Universitário de Palmas - Curso de Ciências da Computação,
2022.
Orientadora : Juliana Leitão Dutra

1. Reconhecimento Facial. 2. Biometria. 3. Viés Algorítmico. 4.
Discriminação Algorítmica. I. Título

CDD 004

TODOS OS DIREITOS RESERVADOS – A reprodução total ou parcial, de
qualquer forma ou por qualquer meio deste documento é autorizado desde
que citada a fonte. A violação dos direitos do autor (Lei nº 9.610/98) é crime
estabelecido pelo artigo 184 do Código Penal.

**Elaborado pelo sistema de geração automática de ficha catalográfica
da UFT com os dados fornecidos pelo(a) autor(a).**

HUMBERTO MARTINS MENDONÇA DUARTE

VIÉS RACIAL EM ALGORITMOS DE RECONHECIMENTO FACIAL POR
HISTOGRAMAS DE GRADIENTES ORIENTADOS

Trabalho de Conclusão de Curso II apresentado à UFT – Universidade Federal do Tocantins – Câmpus Universitário de Palmas, Curso de Ciência da Computação foi avaliado para a obtenção do título de Bacharel e aprovada em sua forma final pelo Orientador e pela Banca Examinadora.

Data de aprovação: 8 / 7 / 2022

Banca Examinadora:

Prof^a. Dr^a. Anna Paula de Sousa Parente Rodrigues

Prof^a. M^a. Juliana Leitão Dutra

Prof. Dr. Tanilson Dias dos Santos

*À minha querida mãe, cujo
incansável apoio vai além das
palavras.*

AGRADECIMENTOS

Gostaria de agradecer ao Prof. Dr. Eduardo Ferreira Ribeiro por sua orientação durante todo o desenvolvimento deste trabalho, salvo neste momento derradeiro. Sua instrução foi essencial para garantir que este estudo atingisse os padrões da área acadêmica.

Também deixo meus agradecimentos à Prof^a. Dr^a. Anna Paula de S. P. Rodrigues e ao Prof. Dr. Tanilson Dias dos Santos pelas considerações e correções que contribuíram para elevar a qualidade final deste trabalho.

Finalmente, gostaria de manifestar minha gratidão à Prof^a. M^a. Juliana Leitão Dutra e ao Prof. Dr. Rafael Lima de Carvalho por seu suporte indispensável no processo de finalização deste trabalho de conclusão de curso.

RESUMO

Sistemas de reconhecimento facial automatizado têm sido foco de pesquisa e desenvolvimento nos últimos anos, e encontram uso em diversas aplicações comerciais e de segurança, inclusive por instituições policiais. Porém, a confiabilidade das técnicas de avaliação destes sistemas vêm sendo questionada, com análises demonstrando a existência de viés algorítmico demográfico em certas tecnologias de reconhecimento facial contemporâneas. Neste trabalho, uma metodologia de avaliação que leve em consideração a representatividade de características demográficas é elaborada, e esta é aplicada sobre um algoritmo de reconhecimento facial por Histogramas de Gradientes Orientados selecionado, acompanhada de uma análise sobre os resultados observados.

Palavra-chave: Reconhecimento Facial. Biometria. Viés Algorítmico. Discriminação Algorítmica.

ABSTRACT

Automated face recognition systems have received extensive research and development in the past few years, and have been applied to several commercial and security applications, as well as uses by police institutions. However, the reliability of the evaluation techniques over these systems have been brought into question, with analysis highlighting the existence of algorithmic bias within certain face recognition technologies. In this work, an evaluation methodology that takes demographic representativity into consideration is elaborated, which is then applied to a chosen facial recognition algorithm based on Histograms of Oriented Gradients, followed by an analysis is performed over the obtained results.

Keywords: Face Recognition. Biometrics. Algorithmic Bias. Algorithmic Discrimination.

LISTA DE SIGLAS

DMMA	Discriminative Multi-Manifold Analysis, p. 29
FERET	Facial Recognition Technology, p. 29
HOG	Histogram of Oriented Gradients, p. 16
IIQ	Intervalo Intercuartil, p. 33
LFW	Labeled Faces in the Wild, p. 29
MLPD	Multi-layer Perceptron based Distance, p. 28
MMD	Mean of Minimum Distances, p. 28
MS-CFB	Multi-Subregion based Correlation Filter Bank, p. 29
MSRS	Most Similar Region Selection, p. 26
RMSE	Root-Mean-Square Error, p. 27
TFP	Taxa de Falsos Positivos, p. 33
YFCC100M	Yahoo Flickr Creative Commons 100 Million, p. 34

LISTA DE ALGORITMOS

1	Seleção da Região Mais Semelhante (MSRS)	26
---	--	----

LISTA DE FIGURAS

Figura 1 – Visão Geral dos Procedimentos de Avaliação e Análise	30
Figura 2 – Exemplo das Imagens Faciais Presentes no Conjunto FairFace	34
Figura 3 – Distribuição do Conjunto FairFace, por Rótulos de Idade e Gênero	35
Figura 4 – Distribuição do Conjunto FairFace, por Rótulos de Raça e Gênero	36
Figura 5 – Distribuição de Valores de Distância, sem Divisões por Rótulo	37
Figura 6 – Taxa de Falsos Positivos sobre Valores de Limite, sem Divisões por Rótulo	38
Figura 7 – Distribuição de Valores de Distância, por Rótulo de Gênero	39
Figura 8 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo de Gênero	40
Figura 9 – Proporções de Correspondência às Amostras, por Rótulo de Gênero	40
Figura 10 – Distribuição de Valores de Distância, por Rótulo de Idade	41
Figura 11 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo de Idade	42
Figura 12 – Proporções de Correspondência às Amostras, por Rótulo de Idade	43
Figura 13 – Distribuição de Valores de Distância, por Rótulo de Raça	44
Figura 14 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo de Raça	45
Figura 15 – Proporções de Correspondência às Amostras, por Rótulo de Raça	46
Figura 16 – Distribuição de Valores de Distância, sem Divisões por Rótulo	52
Figura 17 – Distribuição de Valores de Distância, por Rótulo “Masculino”	53
Figura 18 – Distribuição de Valores de Distância, por Rótulo “Feminino”	53
Figura 19 – Distribuição de Valores de Distância, por Rótulo de Idade Entre 20 e 29 Anos	54
Figura 20 – Distribuição de Valores de Distância, por Rótulo de Idade Entre 30 e 39 Anos	54
Figura 21 – Distribuição de Valores de Distância, por Rótulo de Idade Entre 40 e 49 Anos	55
Figura 22 – Distribuição de Valores de Distância, por Rótulo de Idade Entre 50 e 59 Anos	55

Figura 23 – Distribuição de Valores de Distância, por Rótulo de Idade de 60 Anos ou Mais	56
Figura 24 – Distribuição de Valores de Distância, por Rótulo “Branco”	56
Figura 25 – Distribuição de Valores de Distância, por Rótulo “Latino/Hispanico”	57
Figura 26 – Distribuição de Valores de Distância, por Rótulo “Indiana”	57
Figura 27 – Distribuição de Valores de Distância, por Rótulo “Leste Asiática”	58
Figura 28 – Distribuição de Valores de Distância, por Rótulo “Negro”	58
Figura 29 – Distribuição de Valores de Distância, por Rótulo de “Sudeste Asiática”	59
Figura 30 – Distribuição de Valores de Distância, por Rótulo “Oriente Médio”	59
Figura 31 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo “Masculino”	60
Figura 32 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo “Feminino”	61
Figura 33 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo de Idade Entre 20 e 29 Anos	61
Figura 34 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo de Idade Entre 30 e 39 Anos	62
Figura 35 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo de Idade Entre 40 e 49 Anos	62
Figura 36 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo de Idade Entre 50 e 59 Anos	63
Figura 37 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo de Idade de 60 Anos ou Mais	63
Figura 38 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo “Branco”	64
Figura 39 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo “Latino/Hispanico”	64
Figura 40 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo “Indiana”	65
Figura 41 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo “Leste Asiática”	65
Figura 42 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo “Negro”	66
Figura 43 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo “Sudeste Asiática”	66

Figura 44 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo	
“Oriente Médio”	67

LISTA DE TABELAS

Tabela 1 – Combinações de Parâmetros Utilizadas no Algoritmo Multi-HOG	28
--	----

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Problemática Observada	17
1.2	Objetivos	17
2	FUNDAMENTAÇÃO TEÓRICA	19
2.1	Biometria	19
2.1.1	História	19
2.1.2	Métodos de Reconhecimento Biométrico	19
2.1.3	Desafios	20
2.2	Reconhecimento Facial	21
2.2.1	História	21
2.2.2	Aplicações	21
2.2.3	Categorias	22
2.2.4	Desafios	22
2.3	Trabalhos Relacionados	23
2.3.1	Distribuição Demográfica em Conjuntos de Dados	23
2.3.2	Viés Algorítmico em Inteligência Artificial	24
3	ALGORITMO MULTI-HOG	25
3.1	Introdução	25
3.2	Funcionamento do Algoritmo	25
3.3	Estrutura Experimental	29
4	METODOLOGIA	30
4.1	Modelagem Matemática	30
4.2	Método de Avaliação e Análise	32
4.2.1	Procedimento de Avaliação	32
4.2.2	Procedimento de Análise	33
4.3	Conjunto de Dados	34

4.3.1	Características Técnicas	35
4.3.2	Características Demográficas	35
5	RESULTADOS E ANÁLISE	37
5.1	Escopo Geral	37
5.2	Escopo Demográfico	38
5.2.1	Por Rótulo de Gênero	39
5.2.2	Por Rótulo de Idade	41
5.2.3	Por Rótulo de Raça	43
6	CONCLUSÕES	47
6.1	Trabalhos Futuros	47
	REFERÊNCIAS	48
A	DISTRIBUIÇÕES DE VALORES DE DISTÂNCIA	52
A.1	Sem Divisões por Rótulo	52
A.2	Por Rótulo de Gênero	53
A.3	Por Rótulo de Idade	54
A.4	Por Rótulo de Raça	56
B	DESVIOS DA TAXA DE FALSOS POSITIVOS	60
B.1	Por Rótulo de Gênero	60
B.2	Por Rótulo de Idade	61
B.3	Por Rótulo de Raça	64

1 INTRODUÇÃO

Tecnologias de reconhecimento facial vêm sendo estudadas desde as décadas de 1960 e 1970, por apresentarem um interessante desafio de processamento de imagens e visão computacional. Apesar de trivial para seres humanos, o reconhecimento de faces familiares independentemente das condições de escala, pose, iluminação, e expressão facial é um processo complexo, como evidenciado pelas limitações encontradas por estas tecnologias durante sua introdução (NILSSON, 2009).

Porém, após décadas de pesquisa e desenvolvimento, o reconhecimento facial automatizado se mostra viável através de um amplo número de tecnologias, que encontram uso em diversas aplicações comerciais como: entretenimento, proteção de dados, e, notavelmente, segurança e vigilância pública (ZHAO et al., 2003).

Técnicas de reconhecimento facial não-automatizado já fazem parte das competências utilizadas pelas instituições policiais brasileiras no contexto da perícia criminal (ARRUDA; MORISSON, 2012). Pode se observar, no entanto, um uso mais intenso de tecnologias de reconhecimento facial automatizado como parte das políticas de proteção à segurança pública nos últimos anos, apesar da ausência de medidas legislativas que estabeleçam os limites e padrões a serem seguidos por tais sistemas (SILVA; FRANQUEIRA; HARTMANN, 2021).

Reconhecimento Facial Por Histogramas de Gradientes Orientados

O histograma de gradientes orientados (HOG) é um descritor de características de imagem utilizado em visão computacional, capaz de representar as direções de bordas e gradientes ao redor de regiões de uma determinada imagem de forma robusta, resistente a distorções locais de forma e a mudanças em iluminação e sombreamento (MCCONNELL, 1986; FREEMAN; ROTH, 1994).

Devido a sua aplicabilidade na detecção de objetos, os descritores HOG encontram amplo uso na detecção de pedestres (DALAL; TRIGGS, 2005; ZHU et al., 2006), assim como em técnicas de reconhecimento facial, com diversos algoritmos propostos na literatura (ALBIOL et al., 2008; DÉNIZ et al., 2011; DO; KIJAK, 2012).

Viés Algorítmico

O conceito de viés algorítmico pode ser descrito como uma característica sistemática em um processo automatizado que resulta em comportamentos diferentes sobre grupos arbitrários de usuários. A princípio, é somente um termo neutro descritivo do funcionamento de determinado algoritmo (DANKS; LONDON, 2017).

O foco deste trabalho é sobre a categoria de discriminação algorítmica, onde o comportamento destes sistemas reflete estruturas de discriminação sociais ou culturais preexistentes. No domínio de sistemas de reconhecimento facial, isso se manifesta nas diferenças de precisão e confiabilidade apresentadas para pessoas de diferentes grupos demográficos (PHILLIPS et al., 2011; BUOLAMWINI; GEBRU, 2018; GROTH; NGAN; HANAOKA, 2019).

As instâncias de viés algorítmico observadas em sistemas reais podem ser analisadas em várias categorias, mas para este trabalho, é dado enfoque ao viés técnico: que emerge das limitações ou considerações técnicas durante a formulação ou avaliação do algoritmo (FRIEDMAN; NISSENBAUM, 1996).

1.1 Problemática Observada

Uma parte das críticas feitas a algoritmos de reconhecimento facial se refere a maneira pela qual são testados e analisados. Problemas como o re-enquadramento dos resultados obtidos, de maneira a fazer com que o desempenho observado pareça melhor, já foram levantados em estudos contemporâneos (RAJI; FRIED, 2021).

Também é criticado o uso exclusivo de métricas de predição para a análise destes algoritmos, como taxas de sensibilidade e especificidade que, apesar de informativas, ocultam a granularidade real dos resultados obtidos (BUOLAMWINI; GEBRU, 2018; GROTH; NGAN; HANAOKA, 2019).

A análise experimental de novos algoritmos é feita, geralmente, sobre conjuntos de dados amplamente utilizados, sob o critério de seus autores. Entretanto, se observa que muitos destes *datasets* não incluem informações sobre a distribuição demográfica dos indivíduos retratados (MUHAMMAD et al., 2021).

Porém mesmo em conjuntos de dados devidamente anotados, ainda pode se observar problemas de sub-representação e sobre-representação dentre os grupos demográficos apresentados, o que vem a proporcionar a perda de generalidade dos resultados obtidos em testes efetuados sobre estes *datasets* (SHANKAR et al., 2017; MERLER et al., 2019; KÄRKKÄINEN; JOO, 2021).

Com estas observações, argumenta-se que análises de algoritmos de reconhecimento facial que não levem em conta aspectos sociais e demográficos são insuficientes para investigar adequadamente o seu desempenho, suas capacidades e limitações, e os impactos da sua utilização.

1.2 Objetivos

Com os problemas levantados na seção anterior em mente, este trabalho tem como objetivo efetuar uma avaliação de um algoritmo de reconhecimento facial por histogramas de gradientes orientados, utilizando um conjunto de imagens faciais de escopo demográfico amplo

e diverso, para assim poder averiguar a existência de qualquer viés racial apresentado por este algoritmo.

Para isso, é proposta uma metodologia de avaliação para a qual:

- Um conjunto de dados que atende aos critérios estabelecidos é selecionado.
- Se estabelece um procedimento de avaliação do desempenho com base no conjunto de dados escolhido.
- É determinado um método de análise a partir das propriedades estatísticas descritivas dos resultados obtidos.

O algoritmo de reconhecimento facial escolhido para este trabalho é discutido a fundo no capítulo 3. A metodologia de avaliação proposta e as características do conjunto de dados selecionados são apresentadas no capítulo 4.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Biometria

O reconhecimento facial é uma tarefa do campo da biometria, que estuda os diferentes métodos de aferição de características humanas, sejam físicas ou comportamentais, aplicados principalmente a identificação pessoal e reconhecimento de indivíduos.

2.1.1 História

A biometria tem seus inícios na ciência forense e em órgãos de aplicação da lei, com métodos de identificação de impressões digitais, o que já se nota como ampla prática na década de 70 (JAIN; KUMAR, 2012). Nas décadas seguintes, pode-se observar uma ramificação das aplicações dentro do campo da biometria, que passa a incluir diversos sistemas de reconhecimento de impressões digitais, íris, imagens faciais, dentre outros. Igualmente, se observa um crescimento no número das aplicações para estas técnicas, tanto no cenário governamental quanto no comercial (GATES, 2011; JAIN; KUMAR, 2012).

Com a chegada do novo milênio, e as tensões políticas e sociais decorrentes, o desenvolvimento e uso de tecnologias biométricas, incluindo o reconhecimento facial, passaram a ser consideradas recursos chave para a garantia da segurança pública e nacional, e foram prontamente adotadas no cenário corporativo como medidas de segurança de acesso e monitoramento de ambos clientes e funcionários (GATES, 2011).

2.1.2 Métodos de Reconhecimento Biométrico

Existe um grande número de métodos biométricos, cada um com suas vantagens e desvantagens características, onde a escolha da técnica mais efetiva é feita de acordo com os requisitos de cada aplicação, e o modo pelo qual os atributos biométricos são coletados (JAIN; ROSS; PRABHAKAR, 2004).

Assinatura Um nome ou apelido de uma pessoa, escrito à mão própria, já é usado como prova de identificação ou intenção em documentos a muito tempo. A maneira de escrever seu nome é extremamente característica a cada indivíduo, e é usada como um método de reconhecimento em transações comerciais, legais, e governamentais. No entanto, a assinatura de uma pessoa está sujeita a mudanças com o tempo, a influências físicas e emocionais, e pode ser reproduzida com facilidade por atores mal-intencionados.

DNA O código genético de uma pessoa é, provavelmente, o descritor de identidade mais poderoso possível. Este método tem sido o alvo principal de pesquisa no contexto da ciência

forense para reconhecimento pessoal. Porém, por ser sensível e estar sujeita a contaminação, e por ser um método geralmente invasivo e com alto teor de conhecimento técnico envolvido em sua aplicação, a viabilidade do uso do DNA em demais áreas ainda é considerado limitado.

Faces O reconhecimento de faces, além de não invasivo, é o método de identificação de características pessoais mais utilizado por seres humanos. Esta identificação pode ser feita de modo automatizado a partir da localização de atributos faciais, como os olhos, sobrancelhas, nariz, lábios, e queixo, e a relação espacial entre estes elementos. Outras abordagens focam na extração de estruturas globais que, quando combinadas de forma ponderada, produzem a imagem facial sendo analisada.

Impressões Digitais Impressões digitais têm sido utilizadas para a identificação pessoal por vários séculos, e seu nível de precisão é considerado alto. Uma impressão digital é formada através de elevações microscópicas da pele, e inclui o formato, tamanho, e disposição da palma e dos dedos. Esta é uma técnica de implementação simples, de fácil uso, e possui diversas implementações comerciais disponíveis. Porém, ainda são encontrados problemas com sua aplicação em grandes populações de usuários, e com a variação da informação de geometria da mão ao longo do tempo.

Íris A íris é a parte do olho responsável por controlar o diâmetro e tamanho da pupila em seres humanos e outros vertebrados, e é composta de estruturas pigmentadas que definem a aparência visível dos olhos. Estas estruturas se desenvolvem e se estabilizam durante a infância, até os dois anos de idade. Devido a sua complexidade e distintividade, são consideradas úteis para a identificação pessoal. Pela velocidade e o nível de precisão de implementações existentes, esta técnica é considerada uma das melhores alternativas para sistemas de reconhecimento em larga escala.

Voz A voz de um indivíduo é uma combinação de fatores biométricos fisiológicos e comportamentais, que influenciam a síntese de voz. Estes fatores fisiológicos da fala são específicos a cada indivíduo, mas os fatores comportamentais estão sujeitos a influências como a idade, o estado emocional, e condições médicas. É uma técnica ideal para aplicações em celulares e *smartphones*, mas encontra problemas relacionados a qualidade reduzida do sinal de voz destes canais.

2.1.3 Desafios

Uma grande desvantagem da biometria é a impossibilidade de revogação de descritores biométricos. Ao contrário de uma senha, que pode ser alterada ou invalidada sob critério dos usuários do sistema, as características biométricas, seja a face, voz, ou impressão digital, de

um indivíduo são limitadas, e difíceis de serem alteradas (PRABHAKAR; PANKANTI; JAIN, 2003; RATHA et al., 2006).

Além disso, o uso da biometria em aplicações comerciais e governamentais de reconhecimento pessoal também é rodeado de preocupações com a segurança destas aplicações, e as implicações para a privacidade de seus usuários. As técnicas biométricas de um determinado sistema, por exemplo, pode providenciar informações pessoais de origem biológica sobre seus usuários, o que pode ser a base da discriminação sistemática, seja esta de origem algorítmica ou proposital (PRABHAKAR; PANKANTI; JAIN, 2003).

2.2 Reconhecimento Facial

Por ser uma tarefa de fácil execução por seres humanos, a capacidade de identificar e reconhecer faces de forma automatizada é de grande interesse para vários campos da computação. Inúmeros esforços nas disciplinas de processamento de imagens e visão computacional são aplicados à pesquisa e o desenvolvimento de técnicas de reconhecimento facial não só pelo desafios fundamentais encontrados, mas também pelo grande número de aplicações nas quais esta tecnologia apresenta potencial (JAIN; LI, 2011).

2.2.1 História

O estudo do reconhecimento facial tem seu princípio nos ramos da psicologia, com foco na identificação, reconhecimento, e interpretação de características e expressões faciais, e da antropologia, desde o século 19, onde já se observa interesse nas propriedades identificativas e descritivas das características faciais humanas (GALTON, 1889; ZHAO et al., 2003).

Com o passar do tempo e o surgimento e evolução da computação, o reconhecimento facial automático por máquinas se estabeleceu como uma tecnologia viável, especialmente após avanços críticos alcançados na década de 70 (KELLY, 1971; KANADE, 1977).

Nos anos seguintes, os esforços de pesquisa e desenvolvimento destes sistemas continuaram a acompanhar de perto não só os avanços na capacidade de processamento das tecnologias de computação, como também as inovações teóricas e metodológicas em diversos campos, como na visão computacional e na inteligência artificial (SAMAL; IYENGAR, 1992; CHELLAPPA; WILSON; SIROHEY, 1995; NILSSON, 2009).

2.2.2 Aplicações

As aplicações de sistemas de identificação e reconhecimento facial podem ser categorizadas de três maneiras inter-relacionadas, com base nos requisitos específicos impostos por cada uma delas às entradas e ao processo de reconhecimento (CHELLAPPA; WILSON; SIROHEY, 1995).

Há aplicações que fazem uso de descrições digitais aprofundadas das estruturas faciais identificadas, para permitir a manipulação e modificação destas estruturas de forma coerente,

como por exemplo em técnicas de envelhecimento facial, assim como a reconstrução da estrutura facial tridimensional a partir de coleções de imagens (LANITIS, 2008; KEMELMACHER-SHLIZERMAN; SEITZ, 2021).

Estes requisitos diferem, porém, dos encontrados no domínio da identificação facial a partir de descrições de base humana, como a busca de suspeitos por órgãos de aplicação da lei. Nestas aplicações a capacidade de discernimento de características faciais individuais, sob julgamento perceptual e subjetivo, é exigida com maior prioridade (KLARE; LI; JAIN, 2011).

Identifica-se também a área das aplicações que envolvem a comparação e busca de imagens faciais distintas correspondentes, seja através de instâncias diretas, ou de descritores latentes gerados a partir das imagens originais. Este pode ser considerado o domínio de aplicação mais versátil da tecnologia, com usos que vão da identificação e autenticação pessoal, ao uso no monitoramento, vigilância, e segurança pública. (MOON, 2004; SILVA; FRANQUEIRA; HARTMANN, 2021).

2.2.3 Categorias

Métodos de reconhecimento facial podem ser analisados de acordo com o formato das informações sobre as quais eles operam, já que as características dos elementos presentes em um determinado formato são diretamente relacionadas com o tipo e qualidade das informações que podem ser extraídas (ZHAO et al., 2003).

Por exemplo, no reconhecimento facial a partir de imagens estáticas, a maneira pela qual a posição das características que compõem um rosto são detectadas, como os olhos, nariz, e boca, está relacionada com as propriedades visuais e morfológicas da imagem, como a resolução absoluta da imagem, a escala de nitidez geral, a acuidade de detalhes pequenos, e o formato e intensidade das cores representadas (ZHAO et al., 2003; JAIN; LI, 2011).

Por outro lado, se o sistema de reconhecimento facial é aplicado sobre vídeos ou sequências de imagens temporalmente relacionadas, é adicionada uma nova dimensão de informações que podem ser aproveitadas pelos métodos de identificação e reconhecimento. Porém, aplicações sobre estes formatos se deparam com um conjunto específico de desafios, como a qualidade menor de captura e enquadramento em vídeos, a perda de resolução para as características faciais, e a perda de especificidade de características gerais de rosto e partes do corpo (LI; CHELLAPPA, 2001; LI; GONG; LIDDELL, 2001).

2.2.4 Desafios

Dentre as diferentes abordagens de identificação e reconhecimento facial automatizado, é possível evidenciar dois dos desafios que elas possuem em comum: os problemas de variação de iluminação e variação de pose. Estes problemas são realçados em aplicações onde as imagens faciais são capturadas em ambientes de pouco ou nenhum controle, como fotos amadoras e imagens de câmeras de segurança (ZHAO et al., 2003).

O problema de variação de iluminação pode ser caracterizado pela maneira com a qual a forma de uma determinada face difere sob distintos ângulos e condições de iluminação. Este é um efeito que pode ser experimentalmente observado tanto no contexto do reconhecimento facial automatizado, quando na psicologia e biologia humana (ADINI; MOSES; ULLMAN, 1997; BRAJE et al., 1998).

O nível de desempenho de métodos de reconhecimento facial também é dependente da variação de pose nas imagens faciais de entrada, o que é identificado como um desafio crítico do domínio por diversas avaliações na literatura (BLACKBURN; BONE; PHILLIPS, 2001; ZHANG; GAO, 2009). Este problema pode ser subsequentemente dividido em aspectos de oclusão, proveniente da ausência da informação visual de partes da face, e aspectos de rotação, onde as características estão visíveis porém com variâncias de orientação (WISKOTT et al., 1997; ZHAO et al., 2003).

2.3 Trabalhos Relacionados

2.3.1 Distribuição Demográfica em Conjuntos de Dados

Em seu trabalho, Shankar et al. (2017) efetuam uma análise da distribuição e representação geográfica em conjuntos abertos de imagens, e o impacto desta representação em algoritmos de classificação que os utilizam. Os autores identificam uma predominância eurocêntrica na distribuição destes conjuntos, e apresentam o impacto que possuem na classificação, especialmente quando se trata de cenários culturalmente informados, como esportes, casamentos tradicionais, e formas de trabalho.

Análises sobre a distribuição demográfica de conjuntos de imagens faciais também são efetuadas em trabalhos que apresentam novos *datasets* para atender aos problemas observados. O conjunto Labeled Faces in the Wild, por exemplo, foi introduzido em Huang et al. (2007) com o objetivo de providenciar um conjunto sem restrições no que se refere a pose, iluminação, e qualidade de câmera, assim como também variações de idade, gênero, etnia, vestuário e penteados, dentre outros fatores.

Em Gao et al. (2008), um conjunto de imagens faciais de rostos chineses de larga escala é apresentado, com atenção especial a variações dentro deste conjunto demográfico, com o intuito de providenciar a pesquisadores um *dataset* mais amplo e representativo do mesmo.

Similarmente, no trabalho de Muhammad et al. (2021) é coletado um conjunto de imagens faciais de rostos de sujeitos africanos, com características demográficas cuidadosamente registradas. Estes conjuntos de dados são especialmente relevantes em espaços onde as biometrias faciais chinesa e africana estão sub-representadas.

O conjunto de imagens faciais Diversity in faces, apresentado por Merler et al. (2019), apresenta um extenso conjunto de anotações fenotípicas e demográficas sob a justificativa de apresentar uma base prática para garantir a imparcialidade e precisão no reconhecimento facial.

2.3.2 Viés Algorítmico em Inteligência Artificial

Uma análise efetuada por Friedman e Nissenbaum (1996) apresenta três categorias de viés algorítmico em sistemas computadorizados, discute sobre suas origens e seu papel na discriminação algorítmica, e sugere que a independência do viés deve ser considerada uma característica essencial na avaliação destes algoritmos, assim como a eficiência e precisão.

Um estudo sobre o viés algorítmico em três sistemas comerciais de visão computacional é apresentado por Buolamwini e Gebru (2018), onde foco é dado a classificação de gênero. Neste, os autores encontram uma discrepância de desempenho, onde a precisão de classificação é maior para homens em todos sistemas analisados. Os autores concluem que um aumento na representatividade fenotípica e demográfica em conjuntos de dados faciais é necessária para aumentar a transparência e a responsabilização no campo da inteligência artificial.

Em seu artigo, Phillips et al. (2011) investigam uma fonte de viés racial em sistemas de reconhecimento facial que está relacionada ao efeito psicológico humano onde a capacidade de perceber a identidade única de rostos de outras raças é limitada, em relação à capacidade de perceber a identidade de rostos da sua própria raça. Os autores concluem que a origem demográfica dos algoritmos e a composição demográfica do conjunto de teste afetam a precisão observada destes algoritmos.

Uma análise geral do viés racial e demográfico em sistemas de reconhecimento facial, assim como em seus métodos de avaliação, é apresentada no relatório técnico de Grother, Ngan e Hanaoka (2019), com foco em sistemas comerciais utilizados nos Estados Unidos, e no estudo de sondagem de Raji e Fried (2021), que por sua vez, possui foco no contexto histórico acadêmico do reconhecimento facial.

3 ALGORITMO MULTI-HOG

Para o estudo proposto neste trabalho foi escolhida uma técnica de reconhecimento facial que utiliza o histograma de gradientes orientados como descritor principal considerada representativa do estado da arte para esta aplicação. Neste capítulo é feita a apresentação do algoritmo escolhido, a explicação de seu processo de funcionamento, seguida de uma descrição da estrutura de análise experimental empregada por seus autores originais.

3.1 Introdução

O algoritmo de reconhecimento facial Multi-HOG, apresentado por Karaaba et al. (2015), é uma abordagem ao problema de reconhecimento facial que visa combinar as informações de formato e textura de várias regiões distintas da mesma imagem em um único método robusto.

Isto é feito utilizando múltiplos descritores de histogramas de gradientes orientados, extraídos da mesma imagem a partir de grades sobrepostas com parâmetros distintos, para montar o descritor facial completo. A comparação entre diferentes imagens faciais é feita, então, através do cálculo da distância entre estes descritores de características, utilizando um de dois métodos apresentados pelos autores.

Através deste processo, acoplado a uma técnica de alinhamento de sub-imagem, os autores afirmam observar um desempenho similar a demais algoritmos de reconhecimento facial que também utilizam descritores HOG, sobre conjuntos de imagens faciais de uso frequente.

3.2 Funcionamento do Algoritmo

O funcionamento do algoritmo Multi-HOG pode ser descrito a partir de uma série de passos sequenciais: o pré-processamento das imagens de entrada, o método de alinhamento facial, a função de extração de múltiplos descritores HOG, e os métodos de cálculo de distância entre os descritores encontrados.

Pré-processamento das Imagens de Entrada O algoritmo Multi-HOG é aplicado sobre imagens faciais em escala de cinza, as quais já devem estar aproximadamente alinhadas com relação às características de rosto. Estas entradas são redimensionadas para a resolução padrão de 80×88 .

Como as condições de iluminação das imagens de entrada podem distorcer a aparência das características de rosto e gerar ruído adicional no processo de reconhecimento, é efetuada a padronização do brilho e do contraste de cada imagem, com base na média e desvio padrão dos valores de intensidade de seus *pixels*.

Alinhamento Facial Tanto em *datasets* de imagens faciais quanto em aplicações de mundo real, pode se esperar que hajam pequenos erros de pose e alinhamento facial nas entradas, o que pode vir a causar problemas no processo comparação. Para contornar este problema, os autores empregam um algoritmo que efetua a busca das regiões de maior similaridade geométrica entre um par de imagens faciais sendo comparado.

Este procedimento de seleção da região mais semelhante (MSRS), como descrito no algoritmo 1, itera sobre todas as sub-regiões válidas de uma das entradas, de forma sequencial a cada duas células, e compara a distância entre esta sub-região e a outra entrada.

Algoritmo 1 Seleção da Região Mais Semelhante (MSRS)

função SELEÇÃODAREGIÃOMAISSEMELHANTE(I_a, I_b)

$R_b, dist_b \leftarrow$ Busca(I_a, I_b)

$R_a, dist_a \leftarrow$ Busca(I_b, I_a)

se $dist_b \leq dist_a$ **então**

retorne I_a, R_b

senão

retorne R_a, I_b

fim se

fim função

função BUSCA(I_a, I_b)

$w, h, w_{\max}, h_{\max} \leftarrow 72, 80, 80, 88$

$x, y, x_{\max}, y_{\max} \leftarrow 0, 0, w_{\max} - w, h_{\max} - h$

$regiões, distâncias \leftarrow \{\}, \{\}$

enquanto $x \leq x_{\max}$ **faça**

enquanto $y \leq y_{\max}$ **faça**

enquanto $w \leq w_{\max}$ **faça**

enquanto $h \leq h_{\max}$ **faça**

$R_b \leftarrow I_b[x, y, w, h]$

 ▷ Sub-região extraída da imagem de entrada

$H_q \leftarrow \text{HOG}(I_a)$

$H_w \leftarrow \text{HOG}(R_b)$

 ▷ Onde *HOG* calcula o descritor tradicional

$regiões \leftarrow regiões \cup \{R_b\}$

$distâncias \leftarrow distâncias \cup \{\text{RMSE}(H_q, H_w)\}$

$h \leftarrow h + 2$

fim enquanto

$w \leftarrow w + 2$

fim enquanto

$y \leftarrow y + 2$

fim enquanto

$x \leftarrow x + 2$

fim enquanto

$semelhante \leftarrow \text{argmin}(distâncias)$

retorne $regiões[semelhante], distâncias[semelhante]$

fim função

Para calcular a similaridade entre as regiões, é computado um único descritor de his-

tograma de gradientes orientados tradicional para cada sub-região. Este descritor é calculado utilizando como parâmetros uma grade de 8×8 células e 24 classes de histograma.

Em seguida, é feito o cálculo da raiz quadrada do erro médio (RMSE) dentre os descritores extraídos de cada par de sub-regiões candidato. O par de sub-regiões para qual foi encontrado o menor valor de RMSE é utilizado nos passos de comparação seguintes.

Extração de Múltiplos Descritores A extração de um descritor HOG é feita utilizando os gradientes orientados de intensidade da imagem. As matrizes dos componentes horizontais (G_h) e verticais (G_v) destes gradientes são calculados utilizando os valores dos *pixels* da imagem, (I), de acordo como nas equações 1 e 2.

$$G_h[x, y] = I[x + 1, y] - I[x - 1, y] \quad (1)$$

$$G_v[x, y] = I[x, y + 1] - I[x, y - 1] \quad (2)$$

A partir destes componentes pode então ser calculadas as matrizes de magnitude (M) e de direção (θ) dos gradientes, como nas equações 3 e 4.

$$M = \sqrt{G_h^2 + G_v^2} \quad (3)$$

$$\theta = \arctan \frac{G_v}{G_h} \quad (4)$$

Em seguida as matrizes são divididas em células retangulares, que podem ser definidas pelas suas coordenadas de origem, largura, e altura (x, y, w, h). Para cada uma destas células é calculado um histograma contendo B classes, onde cada uma dessas classes compreende um intervalo de orientações (b_θ).

Portanto, a orientação de cada *pixel* da célula indica a classe do histograma, e a sua magnitude indica o peso a ser adicionado a esta classe. Este cálculo é descrito pelas equações 5 e 6.

$$H(x, y, w, h) = \sum_{j=y}^{y+h} \sum_{i=x}^{x+w} T(i, j, b_\theta) \text{ onde } b_\theta \in B \quad (5)$$

$$T(i, j, b) = \begin{cases} M[i, j] & \text{caso } b = \left\lceil \frac{\theta[i, j]B}{2\pi} \right\rceil \\ 0 & \text{caso contrário} \end{cases} \quad (6)$$

Onde as aplicações tradicionais do histograma de gradientes orientados utilizariam um número de células e de classes constante e único, o algoritmo Multi-HOG se diferencia por utilizar uma gama de valores diferentes para estes parâmetros. Em sua implementação original, os autores definem como a imagem será dividida em células por um número de linhas e colunas, em conjunto ao número de classes dos histogramas a serem calculados. Um total de onze combinações de parâmetros foram utilizadas, como pode ser visto na tabela 1.

Tabela 1 – Combinações de Parâmetros Utilizadas no Algoritmo Multi-HOG

Nº Linhas	Nº Colunas	Nº Classes
6	6	24
8		
8	7	
2	8	
5		
6		
7		
8	11	
1		
2		
7		

Os histogramas obtidos de cada célula da imagem de entrada, para cada uma das combinações de parâmetros, são coletados para formar o seu descritor final. A ordem na qual os descritores HOG são calculados e coletados é arbitrária, desde que a mesma ordem seja utilizada para ambas as entradas.

Para maior clareza, o conjunto de descritores de HOG coletados nesta etapa será denominado *multi-descritor*. Para os parâmetros utilizados na implementação original do algoritmo Multi-HOG, o multi-descritor de cada imagem é composto de 474 histogramas individuais.

Cálculo da Distância Uma vez que os multi-descritores foram extraídos das imagens de amostra (M_A) e de referência (M_R), o cálculo do valor médio de distância entre eles é feito em duas partes. Na primeira, um conjunto de distâncias é construído, sobre o qual uma de duas funções de cálculo de distância é aplicada.

O conjunto de distâncias para um par de entradas ($D_{A,R}$) é composto da distância euclidiana entre cada um dos histogramas correspondentes coletados em seu multi-descritor, como denotado na equação 7.

$$D_{A,R} = \{d(h_A, h_R) \mid h_A \in M_A \text{ e } h_R \in M_R\} \quad (7)$$

Este conjunto de distâncias é, finalmente, utilizado para computar um valor único que quantifica a similaridade entre as duas imagens faciais. Para isso, os autores apresentam dois métodos diferentes: a média de distâncias mínimas (MMD) e a distância por *perceptron* multi-camadas (MLPD). Para os propósitos deste trabalho, apenas a o procedimento MMD é considerado para avaliação.

O método da média de distâncias mínimas consiste em selecionar um subconjunto D_s composto apenas dos menores valores do conjunto de distâncias $D_{A,R}$, como descrito na equação 8. Isto é feito para contornar o ruído que oclusões, acessórios, ou expressões faciais podem causar nos resultados. No trabalho original, o subconjunto D_s é limitado pelos autores a apenas

metade dos valores em $D_{A,R}$.

$$D_s = \{x \in D_{A,R} \mid (\forall y \in D_{A,R}) y < x \leftrightarrow y \in D_s\}$$

$$|D_s| = \left\lfloor \frac{|D_{A,R}|}{2} \right\rfloor \quad (8)$$

O valor da distância entre as duas imagens de entrada (d_s) é obtido através da média aritmética dos valores do subconjunto de distâncias mínimas D_s .

3.3 Estrutura Experimental

Para avaliar o desempenho do algoritmo Multi-HOG, os autores efetuam uma série de testes sob diferentes perspectivas, comparando os seus resultados. Estes testes são feitos sobre as imagens faciais presentes nos conjuntos de dados FERET e LFW (PHILLIPS et al., 2000; HUANG et al., 2007), dos quais também é gerado um conjunto de dados suplementar a partir do espelhamento horizontal das imagens originais. Isto é feito de forma a simular características faciais assimétricas e poses faciais não-frontais.

Os testes são constituídos da busca de uma imagem facial correspondente a uma imagem de amostra, e são feitos em separado para os conjuntos de imagens espelhadas e não-espelhadas. Estes são efetuados sob a técnica de validação cruzada de dez subconjuntos, e dos quais são coletadas as estatísticas de média e desvio padrão dos valores de precisão observados, o que quantifica o desempenho de cada método.

Primeiramente, o desempenho do algoritmo Multi-HOG é analisado sob várias combinações de parâmetros diferentes, como as configurações de extração de descritores e os diferentes métodos de cálculo de distância. Os parâmetros encontrados nestes testes que foram considerados ideais pelos autores foram utilizados na implementação do algoritmo para este trabalho.

Em seguida, é feita a comparação do uso de apenas um conjunto de descritores HOG, como é aplicado tradicionalmente, com a utilização de múltiplos descritores, como é a abordagem do algoritmo Multi-HOG. Para estes testes, os autores encontram que a precisão média obtida pelo método Multi-HOG é superior sob todas as configurações aplicadas.

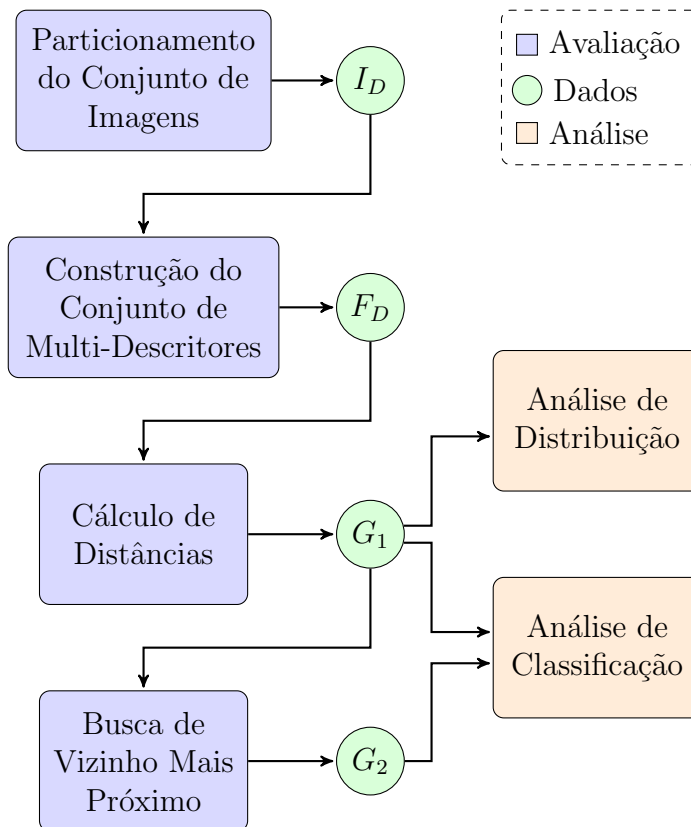
Finalmente, é efetuada uma comparação com dois métodos de reconhecimento facial diferentes que também apresentam uma abordagem de extração sobre múltiplas sub-regiões de imagens faciais. São estes os algoritmos de análise discriminativa multi-variedade (DMMA), e banco de filtros de correlação baseado em multi-sub-regiões (MS-CFB) (LU; TAN; WANG, 2011; YAN; WANG; SUTER, 2014).

Em sua análise dos resultados, os autores observam que o algoritmo Multi-HOG combinado ao método MSRS obteve o melhor desempenho para ambos os conjuntos de dados, principalmente quando as imagens faciais espelhadas são utilizadas. Os autores também notam que o algoritmo obteve desempenho comparável ou superior ao obtido pelos métodos DMMA e MS-CFB, demonstrando a eficiência deste método.

4 METODOLOGIA

Neste capítulo, é discutida a metodologia de avaliação elaborada para atender à problemática levantada. Este processo é caracterizado por uma série de etapas sequenciais, que podem ser classificadas de duas maneiras: etapas de avaliação, durante a qual dados são produzidos, processados, e coletados, e etapas de análise, onde estes dados são investigados e pelas quais as conclusões para as questões levantadas são tomadas. Um diagrama delineando o processo de avaliação elaborado pode ser visto na figura 1.

Figura 1 – Visão Geral dos Procedimentos de Avaliação e Análise



Primeiramente, a modelagem matemática usada neste trabalho é delineada na seção 4.1, juntamente com os termos e palavras-chave que são utilizados. Em seguida, o método avaliativo utilizado é descrito em detalhes na seção 4.2. Por fim, a seção 4.3 apresenta o conjunto de dados selecionado para esta avaliação, e suas características.

4.1 Modelagem Matemática

O algoritmo de reconhecimento facial abordado neste trabalho é aplicado através de duas etapas: a construção de um multi-descritor de características a partir de imagens faciais de referência, seguido da equiparação entre uma dada imagem de amostra e uma das imagens de

referência. Os procedimentos utilizados para a execução destas duas etapas podem ser decompostos em três mecanismos fundamentais:

1. Extração do multi-descritor de uma imagem facial.
2. Cálculo da distância entre dois multi-descritores.
3. Identificação de imagens faciais correspondentes.

Os processos que compõem estes mecanismos são detalhados a fundo no capítulo 3, e portanto serão referenciados a seguir de forma generalizada. O mecanismo de extração do multi-descritor de características, por exemplo, pode ser encapsulado como a função *features*, descrito na equação 9, que tem como domínio (I) as imagens de entrada, e como contradomínio (F) o conjunto de multi-descritores resultantes do processo de extração.

$$\text{features} : I \rightarrow F \quad (9)$$

O procedimento para o cálculo da distância entre dois multi-descritores distintos apresentado pelo algoritmo é denotado de forma genérica na equação 10. Esta função possui como domínio os pares de multi-descritores, e seu contradomínio é o conjunto de números reais não-negativos.

$$\text{distance} : F^2 \rightarrow \mathbb{R}_{\geq 0} \quad (10)$$

Apesar de ser referida como tal, a função de distância fornecida pelo algoritmo Multi-HOG não constitui uma métrica de distância adequada, pois não satisfaz a desigualdade triangular. Porém, se mantém a premissa fundamental de que a similaridade entre um par de multi-descritores $(x, y) \in F^2$ é inversamente proporcional ao valor da distância entre eles ($\text{distance}(x, y)$).

Uma vez que se possua um conjunto de multi-descritores de imagens faciais de referência (F_R), pode-se definir o mecanismo de identificação de imagens correspondentes como o classificador de primeiro vizinho mais próximo (1-NN) sobre a distância entre cada elemento em F_R e o multi-descritor de uma imagem facial de amostra (f_A). Este procedimento é descrito pela função *match*, de acordo como detalhado na equação 11.

$$\begin{aligned} \text{match} : F &\rightarrow F_R \\ f_A &\mapsto f_R \mid \text{distance}(f_A, f_R) = \min_{f_i \in F_R} (\text{distance}(f_A, f_i)) \end{aligned} \quad (11)$$

Finalmente, o processo completo de reconhecimento facial pode ser descrito da seguinte

maneira:

Dada uma imagem de amostra: $i_A \in I, f_A = \text{features}(i_A)$

Encontre a imagem de referência: $i_R \in I_R, f_R = \text{features}(i_R)$

Tal que: $f_R = \text{match}(f_A)$

Nota-se que diversas aplicações de sistemas de reconhecimento facial efetuam uma classificação binária a partir da comparação da imagem de amostra com as entradas de um conjunto de referência pré-estabelecido. Isto é usualmente feito através do cálculo dos valores de distância seguido da filtragem das entradas que ultrapassem um determinado valor limite, emitindo uma classificação positiva ou negativa de acordo.

4.2 Método de Avaliação e Análise

Para investigar a problemática proposta neste trabalho, o algoritmo Multi-HOG é sujeito a um processo de avaliação efetuado utilizando os procedimentos descritos no capítulo 3 e na seção 4.1, e com base no conjunto de dados descrito na seção 4.3. Durante esta avaliação são coletadas métricas de desempenho e estatísticas sobre os resultados obtidos, que são utilizadas em um processo de análise subsequente.

4.2.1 Procedimento de Avaliação

O conjunto de imagens faciais selecionado para a avaliação é pré-processado como exige o processo do algoritmo Multi-HOG, e as entradas resultantes são coletadas no conjunto I_D . Para cada uma destas entradas é extraído um multi-descritor, os quais são coletados no conjunto de dados F_D , como denotado na equação 12.

$$F_D = \{\text{features}(i) \mid i \in I_D\} \quad (12)$$

Em seguida, é calculado um valor de distância para cada um dos os pares de multi-descritores distintos presentes em F_D , que é registrado no conjunto de nome G_1 . A partir destas distâncias, o mecanismo de identificação do algoritmo é utilizado para encontrar o multi-descritor mais próximo de cada entrada em F_D , fora ela mesma. Estes pares são registrados em uma estrutura de nome G_2 .

$$G_1 = \{\text{distance}(x, y) \mid x \in F_D \text{ e } y \in F_D \text{ e } x \neq y\} \quad (13)$$

$$G_2 = \{(x, y) \mid x \in F_D \text{ e } y = \text{match}(x) \text{ e } x \neq y\} \quad (14)$$

Na execução do algoritmo, a geração de ambas as estruturas G_1 e G_2 é feita juntamente com o registro dos rótulos das imagens associadas a cada multi-descritor nelas contido, para que estas informações possam ser utilizadas na análise subsequente.

4.2.2 Procedimento de Análise

O procedimento de análise tem como objetivo investigar o comportamento do algoritmo de reconhecimento facial em situações onde as amostras sendo examinadas não correspondem ao mesmo sujeito, ou seja, onde um valor de predição negativa seria esperado.

Situações como esta podem ocorrer, por exemplo, caso o sujeito de teste não esteja registrado no conjunto de dados de referência do sistema utilizado, ou caso a amostra sendo processada não resulte em descritores de qualidade suficiente para o algoritmo. Estes casos são especialmente importantes em aplicações onde o conjunto de referência é incompleto por padrão, como na busca de pessoas desaparecidas ou no monitoramento da segurança pública, onde a taxa de resultados falsos positivos pode impedir o uso prático da aplicação.

Como estabelecido na premissa do procedimento de avaliação, todas as investigações sobre os dados coletados são feitas a partir de três perspectivas diferentes, correspondentes aos rótulos demográficos presentes no conjunto FairFace. Para isto, as estruturas G_1 e G_2 são subdivididas de acordo com o foco de cada análise, sendo estes subconjuntos denotados por G_s .

Sobre os valores de distância entre pares de entradas distintas, coletados na estrutura G_1 , é feita uma visualização de distribuição por histograma normalizado e diagrama de caixa. O número de classes para cada histograma é escolhido através da fórmula de Freedman–Diaconis, aplicada com base no intervalo interquartil (IIQ) do subconjunto sendo visualizado (FREEDMAN; DIACONIS, 1981).

$$\text{Número de classes} = 2 \frac{\text{IIQ}(G_s)}{\sqrt[3]{|G_s|}} \quad (15)$$

Como os pares de entradas comparados em G_1 não são imagens faciais correspondentes, podemos efetuar uma classificação binária sobre os valores de distância do subconjunto G_s através de um valor de limite t arbitrário, como descrito na equação 16.

$$\text{Correspondem}(x, y) = \begin{cases} \text{Verdadeiro} & \text{caso } G_s[x, y] \leq t \\ \text{Falso} & \text{caso contrário} \end{cases} \quad (16)$$

Percorrendo por todos os valores de limite possíveis em t , e efetuando a classificação correspondente sobre G_s , podemos traçar a taxa de falsos positivos (TFP) de classificação para cada um dos rótulos sendo analisados. Além disso, calculamos a diferença entre as taxas de cada subconjunto e o valor observado para o conjunto completo, para obtermos o desvio da TFP associado a cada rótulo.

Sobre os pares de entradas correspondentes na estrutura G_2 , coletados através do mecanismo de vizinho mais próximo do algoritmo, efetuamos a análise da proporção dos rótulos das entradas de referência correspondidas a cada entrada de amostra, utilizando os mesmos rótulos. Como todas as correspondências em G_2 constituem falsos positivos, esta análise nos informa se um par de entradas de um rótulo qualquer possui maiores chances de ser incorretamente

correspondido se comparado a pares de entradas de rótulos diferentes.

4.3 Conjunto de Dados

A avaliação proposta neste trabalho é efetuada utilizando o conjunto de imagens faciais FairFace, proposto por Kärkkäinen e Joo (2021) com o intuito de mitigar o viés racial observado nos conjuntos de imagens faciais existentes. O conjunto é composto de 97.698 imagens rotuladas, montado com ênfase em equilíbrio de composição racial, a partir de imagens coletadas do *dataset* “Yahoo Flickr Creative Commons 100 Million” (YFCC100M) (THOMEE et al., 2016).

Todas as imagens escolhidas para o conjunto FairFace são disponibilizadas pelos autores originais sob a licença *Creative Commons de Atribuição-CompartilhaIgual* (CC BY-SA), que permite tanto o uso acadêmico quanto o comercial. Uma amostra das entradas pode ser vista na figura 2.

Figura 2 – Exemplo das Imagens Faciais Presentes no Conjunto FairFace



O conjunto FairFace é, em virtude do conjunto de dados do qual foi originado, uma coleção diversa de imagens de cenários do mundo real que retratam uma variedade de condições de captura distintas: horas do dia, ambientes interiores e exteriores, ângulos de composição, e condições de iluminação.

O processo de anotação do *dataset* empregado pelos autores é baseado em um sistema de consenso, onde para cada imagem são designados três rotuladores: caso a maioria dos rotuladores atribuem um mesmo valor para cada entrada, este valor é registrado, e caso contrário, a imagem é reavaliada por outros rotuladores. São descartadas todas as imagens para qual o consenso de rotulação não foi obtido em no máximo duas rodadas.

Para este trabalho, é selecionado um subconjunto de 73.659 entradas do conjunto FairFace, onde são incluídas apenas as imagens de indivíduos anotados como possuindo 20 anos de idade ou mais.

4.3.1 Características Técnicas

O conjunto completo é composto de 97.698 imagens em formato JPEG, nas resoluções de 224×224 e 524×524 *pixels*, selecionadas e extraídas pelos autores do *dataset* YFCC100M, através de um método automatizado.

A região do componente facial detectada em cada imagem original, de no mínimo 50×50 *pixels*, é rotacionada e redimensionada para o tamanho uniforme de 150×150 *pixels*. As imagens finais do conjunto são geradas a partir desta região, dada uma margem de preenchimento.

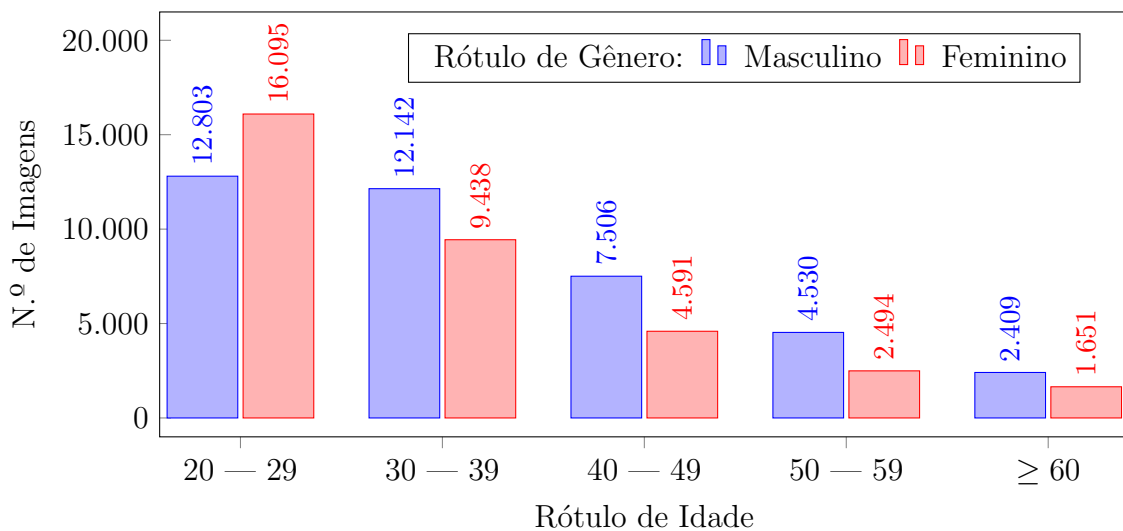
Para uso na análise experimental em seu trabalho original, os autores realizam a separação das entradas do *dataset* em um subconjunto de treino, contendo 86.744 imagens, e um subconjunto de testes, contendo 10.954 imagens.

4.3.2 Características Demográficas

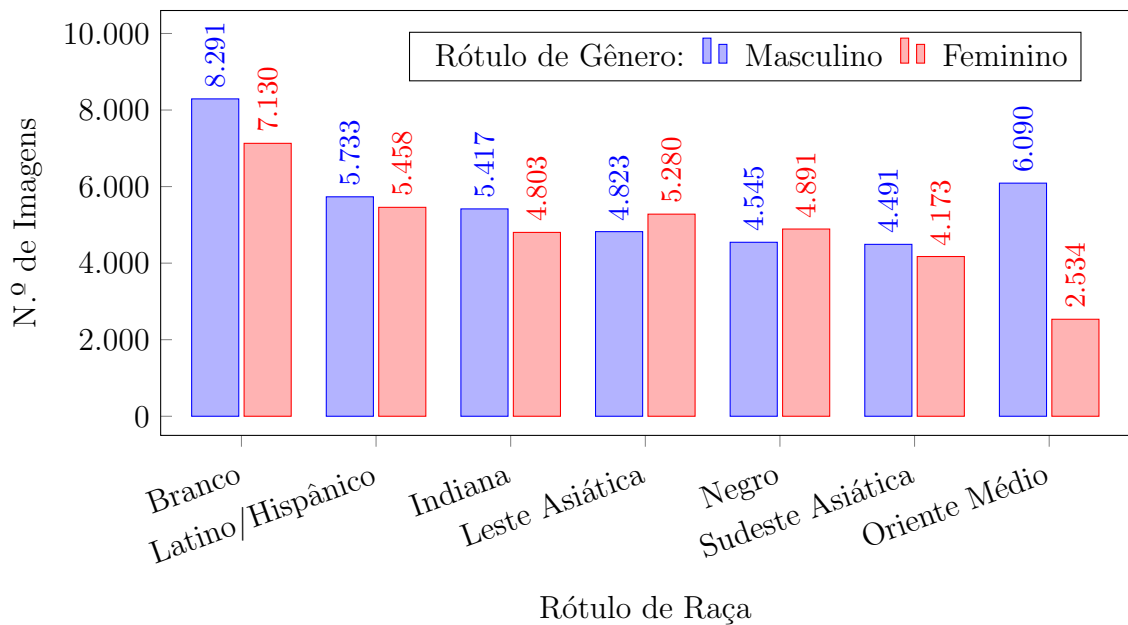
As imagens do conjunto são rotuladas com três valores categóricos contendo a idade, gênero, e raça, atribuídos manualmente cada entrada com base nas características físicas aparentes de cada indivíduo, e no julgamento subjetivo de cada rotulador.

Para os rótulos de raça, os autores se baseiam nas classificações utilizadas pelo Departamento do Censo dos Estados Unidos, seguido de uma subdivisão de justificação própria, a partir de características fenotípicas julgadas aparentemente distintas dentre um mesmo grupo.

Figura 3 – Distribuição do Conjunto FairFace, por Rótulos de Idade e Gênero



Os rótulos dos grupos definidos são, traduzidos de maneira direta: Branco, Negro, Indiana, Leste Asiática, Sudeste Asiática, Oriente Médio, e Latino/Hispanico. Se observa que os termos utilizados variam em significado tanto para o uso regional, quanto ao uso pessoal e interpessoal. Uma distribuição dos rótulos de idade e raça para as entradas do subconjunto selecionado pode ser vista nas figuras 3 e 4.

Figura 4 – Distribuição do Conjunto FairFace, por Rótulos de Raça e Gênero

Devido aos diferentes fatores culturais, políticos, e sociais que afetam a percepção e a autoclassificação das características étnico-raciais de uma pessoa, os rótulos providenciados pelos autores do conjunto FairFace não são considerados, para os propósitos deste trabalho, como uma categorização objetiva e rigorosa dos indivíduos retratados, mas apenas como um agrupamento subjetivo de como os indivíduos possam ser visualmente percebidos.

Visto que as aplicações de mundo real onde os sistemas de reconhecimento facial são empregados estão submetidas as mesmas condições de subjetividade perceptiva, argumenta-se que a representação étnico-racial e a diversidade de expressão cultural e de gênero proporcionada pelo conjunto FairFace é suficiente para atender à problemática observada.


5 RESULTADOS E ANÁLISE

O núcleo deste trabalho é constituído da implementação do algoritmo Multi-HOG, como descrito no capítulo 3, seguido da aplicação da metodologia de avaliação, como elaborada no capítulo 4. Neste capítulo, os resultados obtidos a partir deste processo são delineados, e uma discussão sobre as perspectivas adquiridas para cada um destes é levantada.

5.1 Escopo Geral

Como parte do procedimento de avaliação foram coletados os valores de distância entre pares de multi-descritores distintos, referido como conjunto G_1 . A distribuição do conjunto completo destes valores pode ser visualizada na figura 5.

Figura 5 – Distribuição de Valores de Distância, sem Divisões por Rótulo




A distribuição possui média de 0.02498 e desvio padrão de 0.00454, ambos na unidade de distância, e aparenta seguir uma distribuição normal. Os valores de frequências do histograma utilizado foram normalizados, e este então aproxima a distribuição de densidade de probabilidades do cálculo de distâncias do algoritmo Multi-HOG.

Do ponto de vista agnóstico à implementação, a distribuição observada indica um bom

desempenho do algoritmo: os valores observados são simétricos e bem centrados na média, e estão distribuídos com pouca dispersão relativa a unidade de distância.

Para avaliar o desempenho específico do algoritmo em uma aplicação de classificação binária, podemos simular o uso de diversos valores de limite diferentes para a classificação aplicar cada um deles sobre os dados. Pela natureza do processo de avaliação, a curva resultante traça a taxa de falsos positivos encontrada sobre cada valor de limite.

Figura 6 – Taxa de Falsos Positivos sobre Valores de Limite, sem Divisões por Rótulo



A curva resultante deste processo aplicado a distribuição do conjunto completo pode ser vista na figura 6. Desta podemos observar que para um valor de limite de 0.0195, 10% das comparações efetuadas resultaram, erroneamente, em uma classificação positiva. Da mesma forma, os valores de limite de 0.0246 e 0.0306 resultam em taxas de falsos positivos de 50% e 90%, respectivamente.

Isoladamente, estes valores de limite não dão qualquer perspectiva sobre o desempenho do algoritmo, porém são de suma importância para a implementação de um classificador binário com o algoritmo Multi-HOG em seu núcleo. A complicação, no entanto, se encontra na incapacidade dos dados observados até então de descrever adequadamente o comportamento do algoritmo para diferente grupos demográficos.

5.2 Escopo Demográfico

O método de avaliação proposto se resume em efetuar uma análise dos dados obtidos através de diferentes perspectivas demográficas. Estas foram delineadas seguindo os rótulos categóricos disponibilizados no conjunto de dados FairFace.

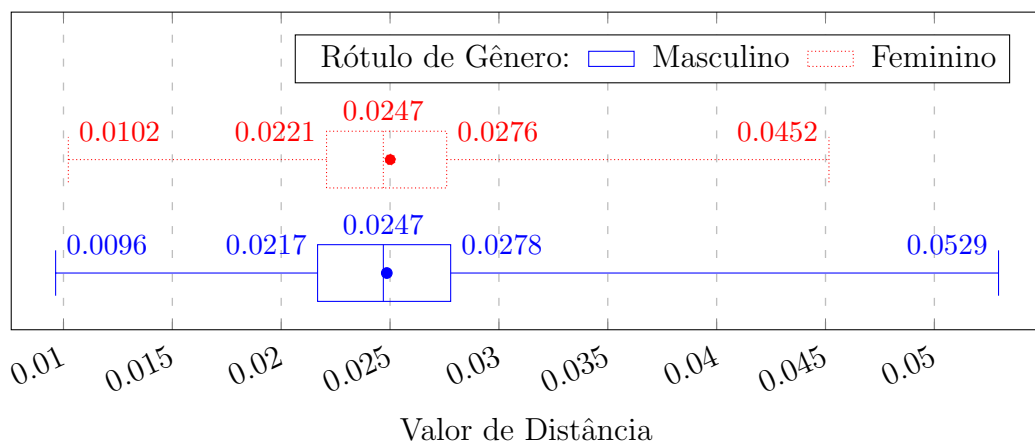
Por uma questão de brevidade e facilidade de comparação, as distribuições de valores de distância nesta seção são visualizadas apenas por diagramas de caixa, o que pode ocultar a granularidade dos dados. A visualização completa das distribuições está disponível no apêndice A.

Igualmente, as curvas de desvio da taxa de falsos positivos sobre valores de limite nesta seção são visualizadas de forma sobreposta, o que pode reduzir a resolução dos dados. A visualização completa das curvas está disponível no apêndice B.

5.2.1 Por Rótulo de Gênero

A partir da distribuição do conjunto completo foram selecionados apenas os valores de distância resultantes de duas entradas possuindo o mesmo rótulo de gênero. As distribuições observadas para estes subconjuntos pode ser vista na figura 7.

Figura 7 – Distribuição de Valores de Distância, por Rótulo de Gênero



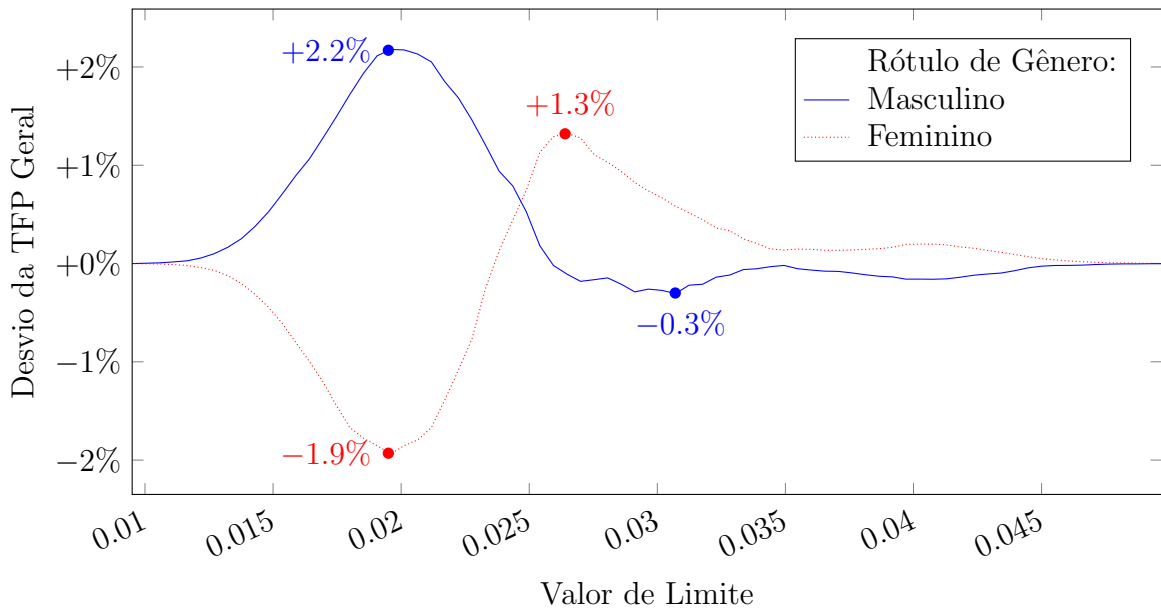
Constata-se que, para esta divisão demográfica, a diferença entre as distribuições é pequena. Os valores observados para o rótulo “Masculino” possui amplitude moderadamente maior, porém os valores compartilham de média e dispersão bastante similares, tanto entre si quanto em relação à distribuição do conjunto completo.

Calculamos, igualmente, a taxa de falsos positivos para valores de limite diferentes sobre estas distribuições, e traçamos o desvio das curvas resultantes em relação a curva obtida para o conjunto completo, como pode ser visto na figura 8.

Observamos uma diferença, embora pequena, do comportamento do algoritmo para os rótulos de gênero: as comparações de entradas de rótulo “Masculino”, em sua pior instância, obtêm uma TFP de cerca de 2% acima do geral observado, ao mesmo tempo que as comparações de rótulo “Feminino” obtêm uma melhora comparável para o mesmo valor de limite.

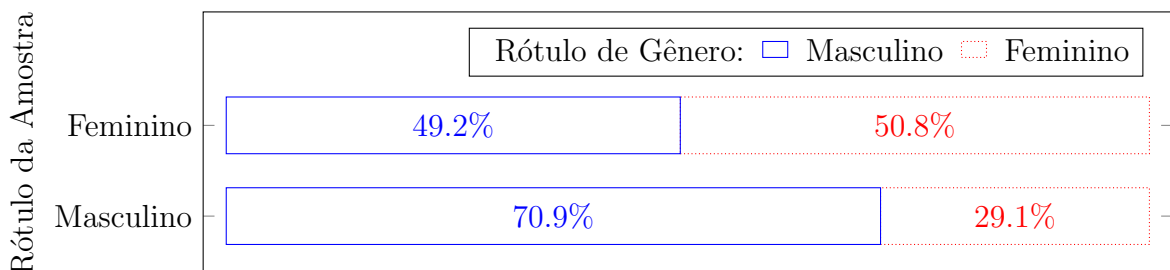
Para um valor de limite mais alto, no entanto, o comportamento das comparações se inverte, embora com menor intensidade, e a taxa de falsos positivos observada para o rótulo “Feminino” fica acima do obtido para o conjunto completo.

Figura 8 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo de Gênero



A partir dos resultados da busca do multi-descritor mais próximo de cada entrada processada, referido como conjunto G_2 , podemos examinar as proporções dos rótulos das entradas de referência correspondidas ao rótulo da entrada de amostra. As proporções observadas para os rótulos de gênero podem ser visualizadas na figura 9.

Figura 9 – Proporções de Correspondência às Amostras, por Rótulo de Gênero



A partir destas informações, notamos que para amostras de rótulo “Masculino”, as entradas de referência de menor distância tendem a possuir o mesmo rótulo. Para as amostras de rótulo “Feminino”, no entanto, a frequência parece estar igualmente distribuída.

Neste caso, uma entrada de amostra de rótulo “Masculino”, por exemplo, possui mais chances de ser correspondida a uma amostra de referência que possui o mesmo rótulo, onde uma amostra de rótulo “Feminino” possui chances similares de ser correspondida a entradas de referência de qualquer rótulo.

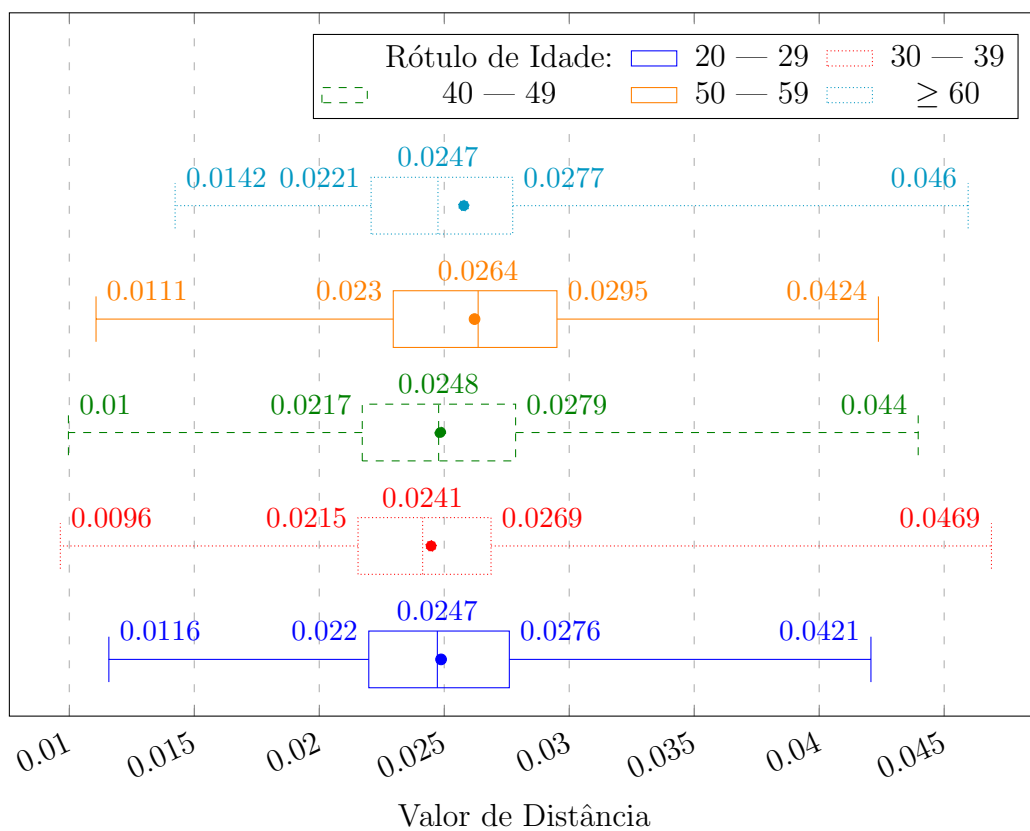
Esta observação se deve ao fato do classificador por vizinho mais próximo selecionar apenas uma entrada de referência por amostra, o que amplifica mesmo as menores discrepâncias nos valores de distância calculados.

Caso utilizado sobre um conjunto de imagens de baixa qualidade de dados, este comportamento implica em uma tendência à classificação incorreta de entradas de rótulo “Feminino”, ao menos no que se refere ao método de vizinho mais próximo.

5.2.2 Por Rótulo de Idade

Selecionamos, novamente, apenas os valores de distância da distribuição do conjunto completo resultantes de duas entradas possuindo o mesmo rótulo de idade. As distribuições observadas para estes subconjuntos pode ser vista na figura 10.

Figura 10 – Distribuição de Valores de Distância, por Rótulo de Idade

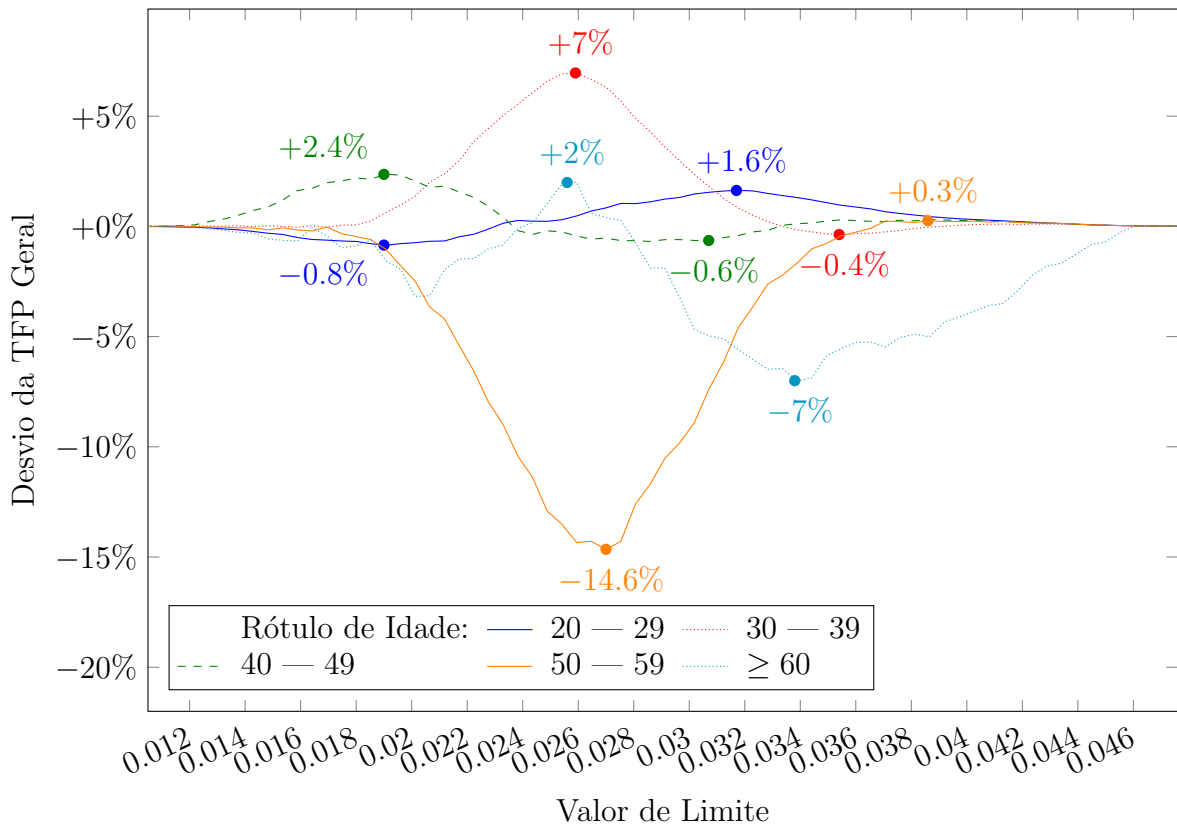


A diferença observada entre as distribuições é alta não só em relação a amplitude dos dados como também às suas dispersões sobre a média. Quanto a isto se destacam as distribuições para os rótulos de “30 — 39” e “50 — 59”.

A assimetria encontrada para as distribuições representa as perspectivas que estariam ocultas por uma análise sem divisões de rótulo demográfico. O desalinhamento entre as estatísticas das distribuições é de maior impacto no que se trata da escolha do valor limite para um classificador binário: caso um valor seja escolhido a partir das estatísticas globais, será dada prioridade não intencional a uma das distribuições, sendo prejudicial em relação às outras.

Em seguida, efetuamos o cálculo da taxa de falsos positivos para valores de limite diferentes sobre estas distribuições, e traçamos o desvio das curvas resultantes na figura 11.

Figura 11 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo de Idade



Neste caso, observamos uma diferença significativamente maior entre os valores de TFP com relação à base global. Em destaque estão os rótulos “50 — 59”, com 14 pontos percentuais para menos, e “30 — 39”, com 7 pontos percentuais para mais.

A princípio, pode-se assumir que uma taxa de falsos positivos inferior ao valor global é um ponto positivo para a aplicação sobre o rótulo correspondente e que o valor de limite associado é, portanto, uma boa escolha para a classificação binária.

Porém, deve-se notar que esta tendência também constitui viés algoritmo, ainda que positiva, pois implica no detrimento do desempenho de classificação sobre as entradas de demais rótulos.

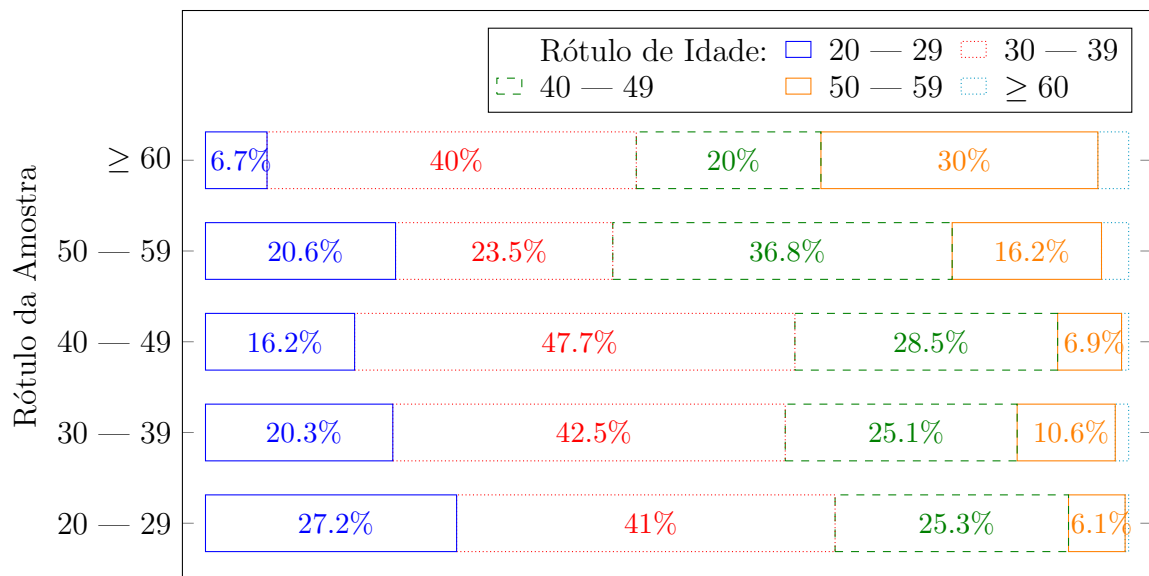
Além dos extremos do desvio observado, destacamos também a diferença no comportamento entre as curvas, com relação ao valor de limite: o intervalo onde se observa a maior discrepância nos dados está posicionado ao redor da média dos valores de distância para o conjunto completo.

Isto implica que, caso a escolha do valor de limite de um classificador binário fosse informada pelas informações da distribuição original sem divisões por rótulo, este classificador resultaria com uma grande discrepância entre estatísticas de classificação, para ao menos metade dos rótulos de idade.

Novamente, podemos examinar as proporções dos resultados da busca do multi-descritor

mais próximo de cada entrada, como pode ser visualizado na figura 12.

Figura 12 – Proporções de Correspondência às Amostras, por Rótulo de Idade



Podemos, novamente, observar o impacto dos valores de distância calculados para a classificação por vizinho mais próximo. Neste caso, os valores das proporções de correspondência aparentam possuir menor relação com os rótulos das entradas sendo comparadas, e mais com a proporção global dos rótulos no conjunto de imagens completo.

Isto implica que o algoritmo Multi-HOG não foi capaz de extrair, em seu mecanismo de descrição, características da imagem que sirvam para o discernimento dos rótulos de idade, ou que seu mecanismo de comparação não foi capaz de diferenciar dentre as características discerníveis que consegue extrair.

Deste modo, concluímos que o cálculo da distância, ao menos em relação aos rótulos de idade, está sujeito a uma maior influência de outros fatores, como a composição total do conjunto de imagens faciais de referência, ou as características representadas pelos demais rótulos.

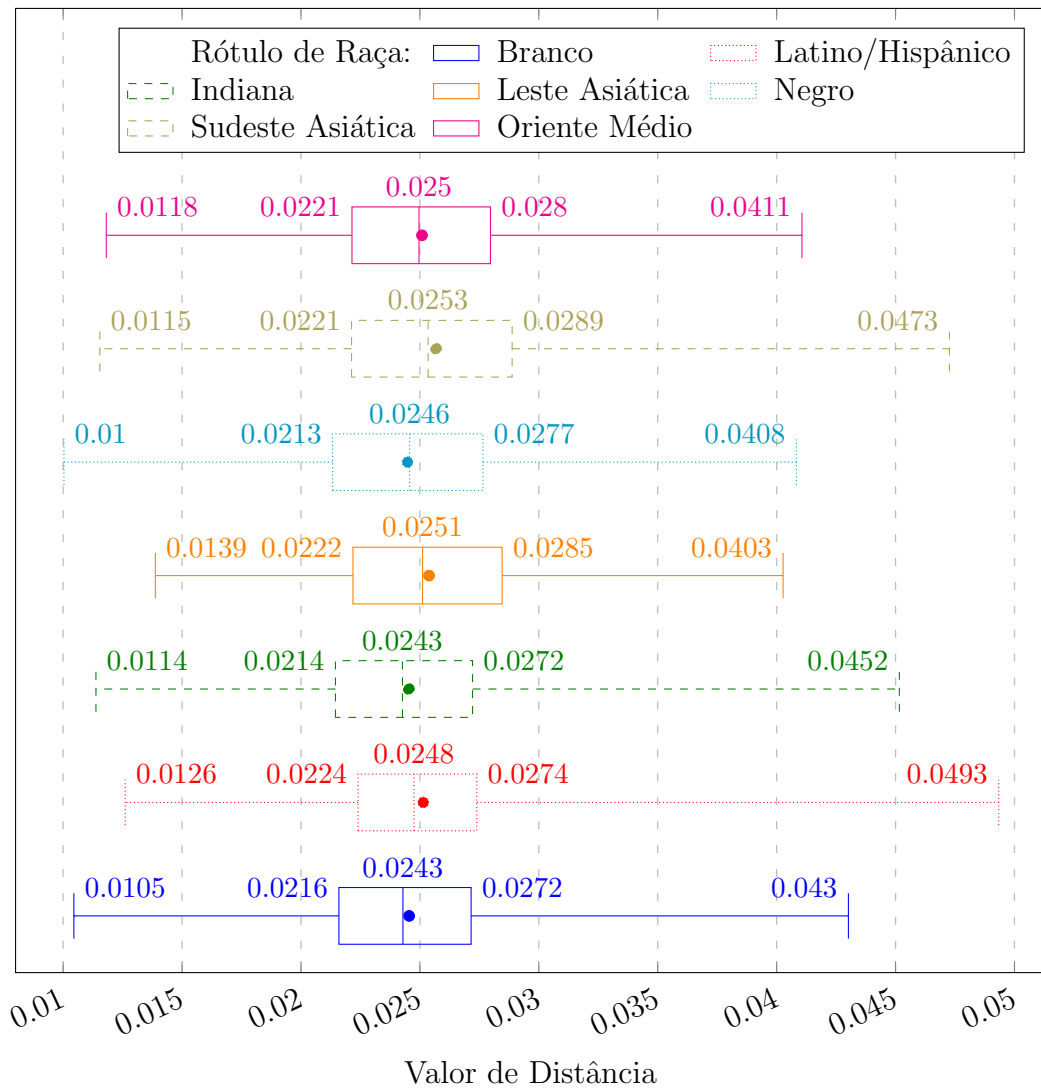
5.2.3 Por Rótulo de Raça

A partir da distribuição do conjunto completo, selecionamos apenas os valores de distância resultantes de duas entradas possuindo o mesmo rótulo de raça, que podem ser visualizados na figura 13.

Podemos constatar novamente um número de diferenças entre as distribuições relacionadas a cada rótulo, com relação aos valores de dispersão e amplitude. De maneira similar às distribuições por rótulo de idade, o valor das médias de cada distribuição se encontram desalinhadas entre si e em relação à distribuição do conjunto completo.

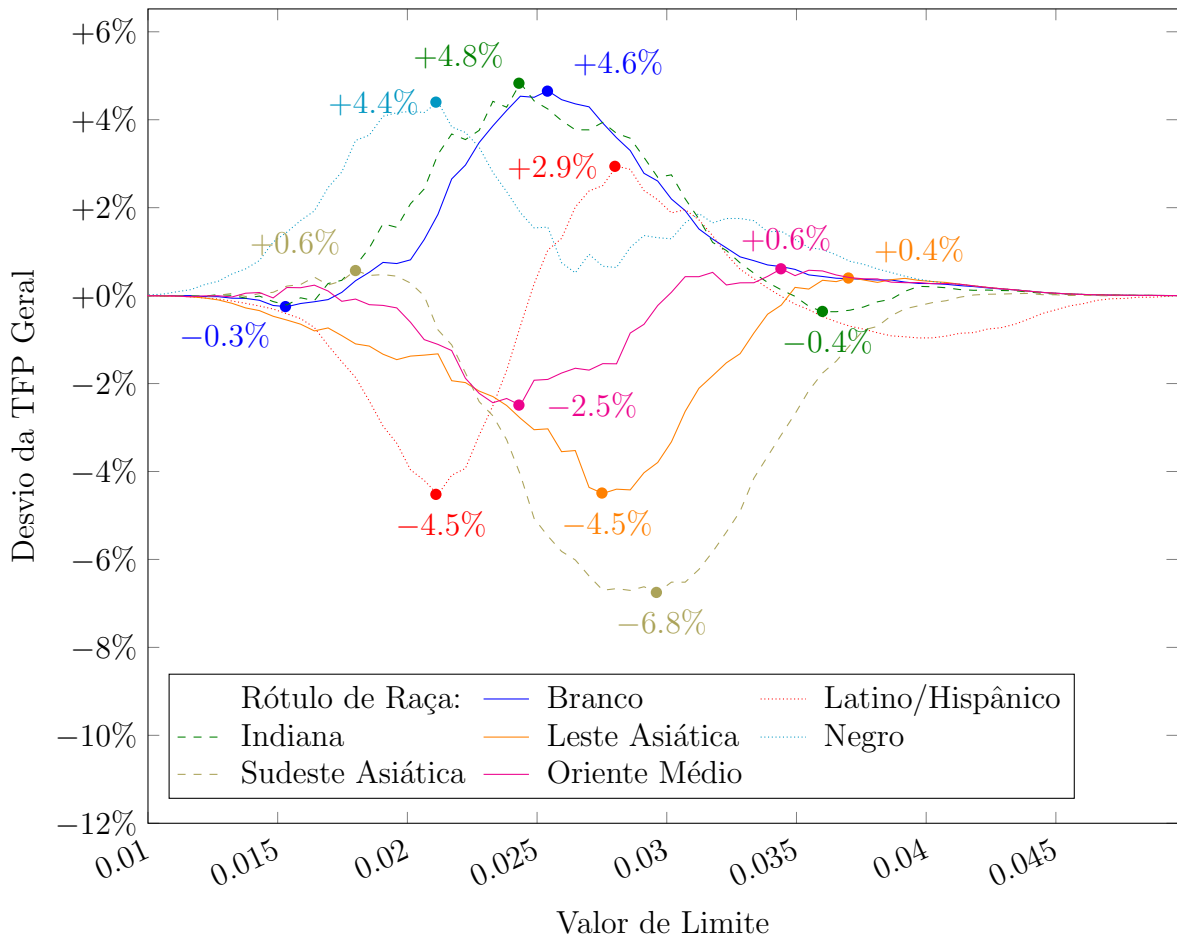
Igualmente, estes fatores possuem maior impacto sobre a escolha de valores de limite para classificação binária. Uma visão melhor deste problema é obtida ao observar o desvio da

Figura 13 – Distribuição de Valores de Distância, por Rótulo de Raça



taxa de falsos positivos para estes valores de limite diferentes em relação a curva obtida para o conjunto completo, como pode ser visto na figura 14.

Figura 14 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo de Raça



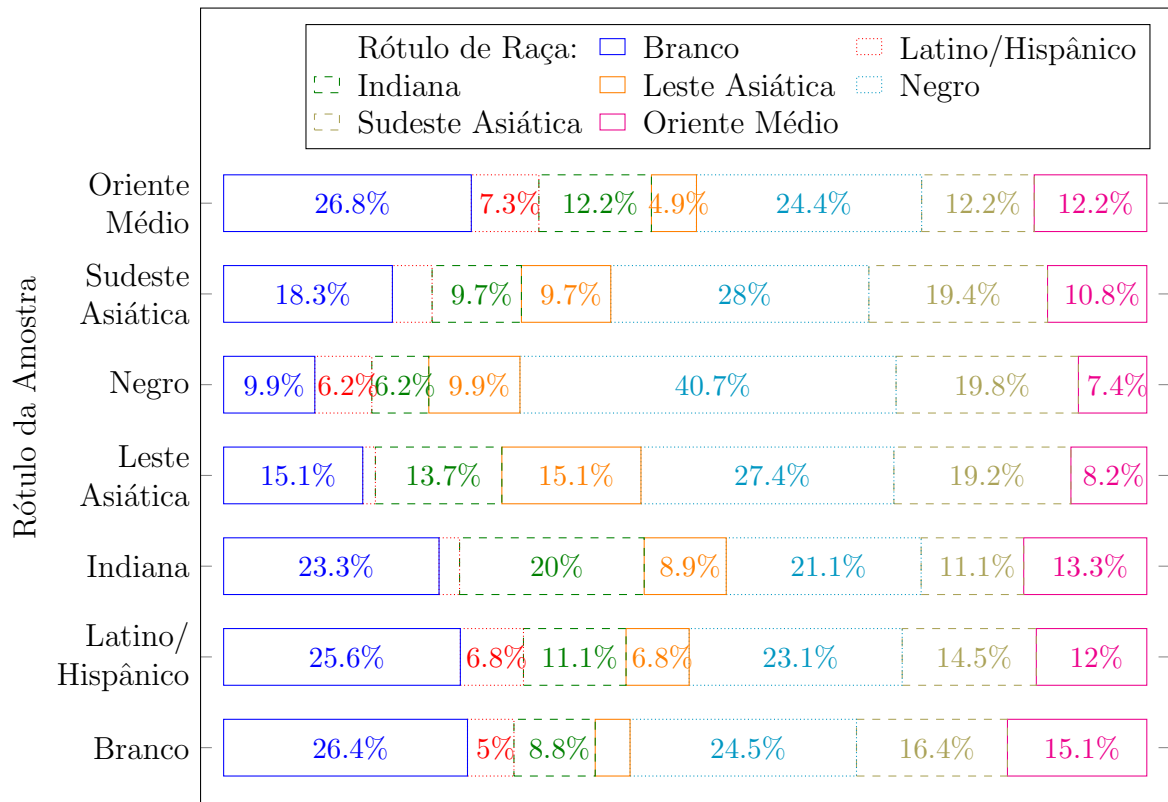
Para os rótulos de raça, podemos observar as curvas de desvio mais discordantes de nossa análise: o desvio que os rótulos “Leste Asiática”, “Sudeste Asiática”, e “Oriente Médio” apresentam é quase exclusivamente negativo, em contraste aos rótulos “Branco”, “Indiana”, e “Negro” que apresentam valor de desvio majoritariamente positivo.

Esta discordância é exacerbada pelo fato dos extremos de cada desvio estarem centrados em valores de limite diferentes, porém ainda próximos da média da distribuição global. Assim como no caso anterior, isto proporciona maiores chances de um classificador binário sobre o algoritmo Multi-HOG apresentar alta tendência de falsos positivos para uma parcela dos rótulos.

Para a análise relevante ao classificador de vizinho mais próximo, observamos as proporções dos resultados da busca para os rótulos de raça na figura 15.

Semelhante aos dados examinados para os rótulos de idade, podemos observar como os valores de distância calculados não apresentam nenhuma tendência de correlação entre amostras de mesmo rótulo. Porém, nesta instância, não se pode identificar a mesma influência da composição do conjunto de dados nos valores observados.

Figura 15 – Proporções de Correspondência às Amostras, por Rótulo de Raça



6 CONCLUSÕES

Neste trabalho, é introduzida a problemática da modelagem e avaliação de algoritmos de reconhecimento facial na ausência de consideração de aspectos demográficos, com foco em métodos baseados em histogramas de gradientes orientados.

Uma metodologia de avaliação e análise que atenda aos problemas levantados é proposta e descrita em conjunto com a modelagem matemática sobre a qual ela se baseia. Também é apresentado o conjunto de dados selecionado para este estudo, como também o algoritmo de reconhecimento facial Multi-HOG, escolhido como alvo da análise proposta.

A princípio, o algoritmo Multi-HOG apresenta um nível de desempenho similar ao descrito pelos autores originais, isto é, quando analisado sobre o conjunto sem divisões demográficas. Porém, ao aplicar a avaliação proposta sobre os diferentes rótulos do conjunto FairFace, as discrepâncias no comportamento do algoritmo se destacam.

Estas diferenças de comportamento impactam, principalmente, decisões de implementação do algoritmo como parte de um sistema de reconhecimento facial maior. Para aplicações de classificação binária, por exemplo, a escolha de valores de limite utilizando somente os dados da análise original estaria, inadvertidamente, sujeita a tendências de classificação que somente a análise demográfica viria a evidenciar.

Os resultados observados servem para evidenciar a argumentação inicialmente proposta: na ausência de análises que levem em conta aspectos demográficos, o entendimento sobre o método de reconhecimento facial, suas capacidades, suas limitações, e os impactos de sua utilização, se encontra incompleto.

6.1 Trabalhos Futuros

Neste trabalho, é examinado apenas um de vários algoritmos de reconhecimento facial presentes na literatura que também utilizam o histograma de gradientes orientados como descritor principal. Alguns destes algoritmos foram considerados para avaliação durante o desenvolvimento do trabalho.

Em Albiol et al. (2008), o algoritmo HOG-EBGM é apresentado, onde o histograma de gradientes orientados é utilizado como o descritor de características principal no lugar das ondaletas Gabor convencionais ao algoritmo EBGM tradicional. Em seu trabalho, Tan, Yang e Ma (2014) propõem três algoritmos de reconhecimento facial que também fazem uso dos descritores HOG, a diferentes níveis de descrição.

De maneira geral, investigações com foco em viés racial e demográfico, efetuadas a partir de conjuntos de imagens construídos sob esta mesma perspectiva, sobre o desempenho de algoritmos de reconhecimento facial já estabelecidos ajudariam a esclarecer e elevar o entendimento do campo como um todo.

REFERÊNCIAS

- ADINI, Y.; MOSES, Y.; ULLMAN, S. Face recognition: The problem of compensating for changes in illumination direction. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, IEEE, v. 19, n. 7, p. 721–732, 1997.
- ALBIOL, A. et al. Face recognition using HOG–EBGM. **Pattern Recognition Letters**, Elsevier, v. 29, n. 10, p. 1537–1543, 2008.
- ARRUDA, G. H. M. de; MORISSON, A. L. d. C. Exames de reconhecimento facial na polícia federal. In: **Anais da Conferência Internacional de Ciências Forenses em Multimídia e Segurança Eletrônica**. Brasília, DF: ACPF, 2012. p. 78–85.
- BLACKBURN, D. M.; BONE, M.; PHILLIPS, P. J. **Face Recognition Vendor Test 2000: Evaluation Report**. Arlington, VA, USA, 2001.
- BRAJE, W. L. et al. Illumination effects in face recognition. **Psychobiology**, Springer, v. 26, n. 4, p. 371–380, 1998.
- BUOLAMWINI, J.; GEBRU, T. Gender shades: Intersectional accuracy disparities in commercial gender classification. In: **Proceedings of the 1st Conference on Fairness, Accountability and Transparency**. New York, NY, USA: PMLR, 2018. v. 81, p. 77–91.
- CHELLAPPA, R.; WILSON, C. L.; SIROHEY, S. Human and machine recognition of faces: A survey. **Proceedings of the IEEE**, IEEE, v. 83, n. 5, p. 705–741, 1995.
- DALAL, N.; TRIGGS, B. Histograms of oriented gradients for human detection. In: **2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)**. San Diego, CA, USA: IEEE, 2005. v. 1, p. 886–893.
- DANKS, D.; LONDON, A. J. Histograms of oriented gradients for human detection. In: **Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence, IJCAI-17**. Melbourne, Australia: IJCAI, 2017. v. 17, p. 4691–4697.
- DÉNIZ, O. et al. Face recognition using histograms of oriented gradients. **Pattern Recognition Letters**, Elsevier, v. 32, n. 12, p. 1598–1603, 2011.
- DO, T.; KIJAK, E. Face recognition using co-occurrence histograms of oriented gradients. In: **2012 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)**. Kyoto, JPN: IEEE, 2012. p. 1301–1304.
- FREEDMAN, D.; DIACONIS, P. On the histogram as a density estimator: L² theory. **Zeitschrift für Wahrscheinlichkeitstheorie und verwandte Gebiete**, Springer, v. 57, n. 4, p. 453–476, 1981.
- FREEMAN, W. T.; ROTH, M. **Orientation Histograms for Hand Gesture Recognition**. Cambridge, MA, USA, 1994.
- FRIEDMAN, B.; NISSENBAUM, H. Bias in computer systems. **ACM Transactions on Information Systems**, Association for Computing Machinery, v. 14, n. 3, p. 330–347, 1996.

- GALTON, F. Personal identification and description. **The Journal of the Anthropological Institute of Great Britain and Ireland**, Wiley, v. 18, p. 177–191, 1889.
- GAO, W. et al. The CAS-PEAL large-scale chinese face database and baseline evaluations. **IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans**, IEEE, v. 38, n. 1, p. 149–161, 2008.
- GATES, K. A. **Our Biometric Future: Facial Recognition Technology and the Culture of Surveillance**. New York, NY, USA: New York University Press, 2011. ISBN 9780814732793.
- GROTHER, P.; NGAN, M.; HANAOKA, K. **Face Recognition Vendor Test Part 3: Demographic Effects**. Gaithersburg, MD, USA: National Institute of Standards and Technology, 2019.
- HUANG, G. B. et al. **Labeled Faces in the Wild: A Database for Studying Face Recognition in Unconstrained Environments**. Amherst, MA, USA, 2007.
- JAIN, A. K.; KUMAR, A. Biometric recognition: An overview. In: MORDINI, E.; TZOVARAS, D. **Second Generation Biometrics: The Ethical, Legal and Social Context**. Dordrecht, Netherlands: Springer, 2012. cap. 3, p. 49–79.
- JAIN, A. K.; LI, S. Z. **Handbook of Face Recognition**. New York, NY, USA: Springer, 2011. ISBN 038740595X.
- JAIN, A. K.; ROSS, A.; PRABHAKAR, S. An introduction to biometric recognition. **IEEE Transactions on Circuits and Systems for Video Technology**, IEEE, v. 14, n. 1, p. 4–20, 2004.
- KANADE, T. **Computer Recognition of Human Faces**. Basel, Switzerland: Birkhäuser Basel, 1977.
- KARAABA, M. F. et al. Robust face recognition by computing distances from multiple histograms of oriented gradients. In: **2015 IEEE Symposium Series on Computational Intelligence**. San Diego, CA, USA: IEEE, 2015. p. 203–209.
- KÄRKKÄINEN, K.; JOO, J. Fairface: Face attribute dataset for balanced race, gender, and age for bias measurement and mitigation. In: **2021 IEEE Winter Conference on Applications of Computer Vision (WACV)**. Waikoloa, HI, USA: IEEE, 2021. p. 1547–1557.
- KELLY, M. D. **Visual Identification of People by Computer**. Stanford, CA, USA: Department of Computer Science, Stanford University, 1971.
- KEMELMACHER-SHLIZERMAN, I.; SEITZ, S. M. Face reconstruction in the wild. In: **2011 International Conference on Computer Vision**. Barcelona, Spain: IEEE, 2011. p. 1746–1753.
- KLARE, B.; LI, Z.; JAIN, A. K. Matching forensic sketches to mug shot photos. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, IEEE, v. 33, n. 3, p. 639–646, 2011.
- LANITIS, A. Evaluating the performance of face-aging algorithms. In: **2008 8th IEEE International Conference on Automatic Face & Gesture Recognition**. Amsterdam, Netherlands: IEEE, 2008. p. 1–6.

- LI, B.; CHELLAPPA, R. Face verification through tracking facial features. **Journal of the Optical Society of America A**, OSA, v. 18, n. 12, p. 2969–2981, 2001.
- LI, Y.; GONG, S.; LIDDELL, H. Constructing facial identity surfaces in a nonlinear discriminating space. In: **2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'01)**. Kauai, HI, USA: IEEE, 2001. p. II–II.
- LU, J.; TAN, Y.; WANG, G. Discriminative multi-manifold analysis for face recognition from a single training sample per person. In: **2011 International Conference on Computer Vision**. San Diego, CA, USA: IEEE, 2011. p. 1943–1950.
- WAYLAND RES INC. Robert K. McConnell. **Method of and Apparatus for Pattern Recognition**. 1986. US Patent 4567610.
- MERLER, M. et al. **Diversity in Faces**. 2019. IBM Research AI at the IBM Thomas J. Watson Research Center.
- MOON, H. Biometrics person authentication using projection-based face recognition system in verification scenario. In: ZHANG, D.; JAIN, A. K. (Ed.). **Biometric Authentication**. Hong Kong, China: Springer, 2004. p. 207–213.
- MUHAMMAD, J. et al. CASIA-Face-Africa: A large-scale african face image database. **IEEE Transactions on Information Forensics and Security**, IEEE, v. 16, p. 3634–3646, 2021.
- NILSSON, N. J. **The Quest for Artificial Intelligence: A History of Ideas and Achievements**. New York, NY, USA: Cambridge University Press, 2009. ISBN 9780521116398.
- PHILLIPS, P. J. et al. An other-race effect for face recognition algorithms. **ACM Transactions on Applied Perception**, Association for Computing Machinery, v. 8, n. 2, p. 1–11, 2011.
- PHILLIPS, P. J. et al. The FERET evaluation methodology for face recognition algorithms. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, IEEE, v. 22, n. 10, p. 1090–1104, 2000.
- PRABHAKAR, S.; PANKANTI, S.; JAIN, A. K. Biometric recognition: Security and privacy concerns. **IEEE Security & Privacy**, IEEE, v. 1, n. 2, p. 33–42, 2003.
- RAJI, I. D.; FRIED, G. **About Face: A Survey of Facial Recognition Evaluation**. 2021. Presented at the AAAI 2020 Workshop on AI Evaluation.
- RATHA, N. et al. Cancelable biometrics: A case study in fingerprints. In: **18th International Conference on Pattern Recognition (ICPR'06)**. Hong Kong, China: IEEE, 2006. v. 4, p. 370–373.
- SAMAL, A.; IYENGAR, P. A. Automatic recognition and analysis of human faces and facial expressions: A survey. **Pattern Recognition**, Elsevier, v. 25, n. 1, p. 65–77, 1992.
- SHANKAR, S. et al. **No Classification without Representation: Assessing Geodiversity Issues in Open Data Sets for the Developing World**. 2017. Presented at the NIPS 2017 Workshop on Machine Learning for the Developing World.

- SILVA, L. A. da; FRANQUEIRA, B. D.; HARTMANN, I. A. O que os olhos não veem, as câmeras monitoram: reconhecimento facial para segurança pública e regulação na américa latina. **Revista Digital de Direito Administrativo**, Universidade de São Paulo, v. 8, n. 1, p. 171–204, 2021.
- TAN, H.; YANG, B.; MA, Z. Face recognition based on the fusion of global and local hog features of face images. **IET computer vision**, Stevenage Institution of Engineering and Technology, v. 8, n. 3, p. 224–234, 2014.
- THOMEÉ, B. et al. YFCC100M: The new data in multimedia research. **Communications of the ACM**, Association for Computing Machinery, v. 59, n. 2, p. 64–73, 2016.
- WISKOTT, L. et al. Face recognition by elastic bunch graph matching. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, IEEE, v. 19, n. 7, p. 775–779, 1997.
- YAN, Y.; WANG, H.; SUTER, D. Multi-subregion based correlation filter bank for robust face recognition. **Pattern Recognition**, Elsevier, v. 47, n. 11, p. 3487–3501, 2014.
- ZHANG, X.; GAO, Y. Face recognition across pose: A review. **Pattern Recognition**, Elsevier, v. 42, n. 11, p. 2876–2896, 2009.
- ZHAO, W. et al. Face recognition: A literature survey. **ACM Computing Surveys**, Association for Computing Machinery, New York, NY, USA, v. 35, n. 4, p. 399–458, 2003.
- ZHU, Q. et al. Fast human detection using a cascade of histograms of oriented gradients. In: **2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'06)**. New York, NY, USA: IEEE, 2006. v. 2, p. 1491–1498.

A DISTRIBUIÇÕES DE VALORES DE DISTÂNCIA


Como parte do procedimento de avaliação descrito na seção 4.2 foram coletadas as distribuições dos valores de distância entre pares de multi-descritores distintos para serem visualizados durante o processo de análise.

Por uma questão de brevidade, estas distribuições foram descritas apenas por diagramas de caixa, o que pode ocultar a granularidade dos dados. A visualização completa das distribuições está disponível nas seções a seguir.

A.1 Sem Divisões por Rótulo

A distribuição de valores de distância sem divisões por rótulo possui média de 0.02498 e desvio padrão de 0.00454 unidades de distância, como visualizada na figura 16.

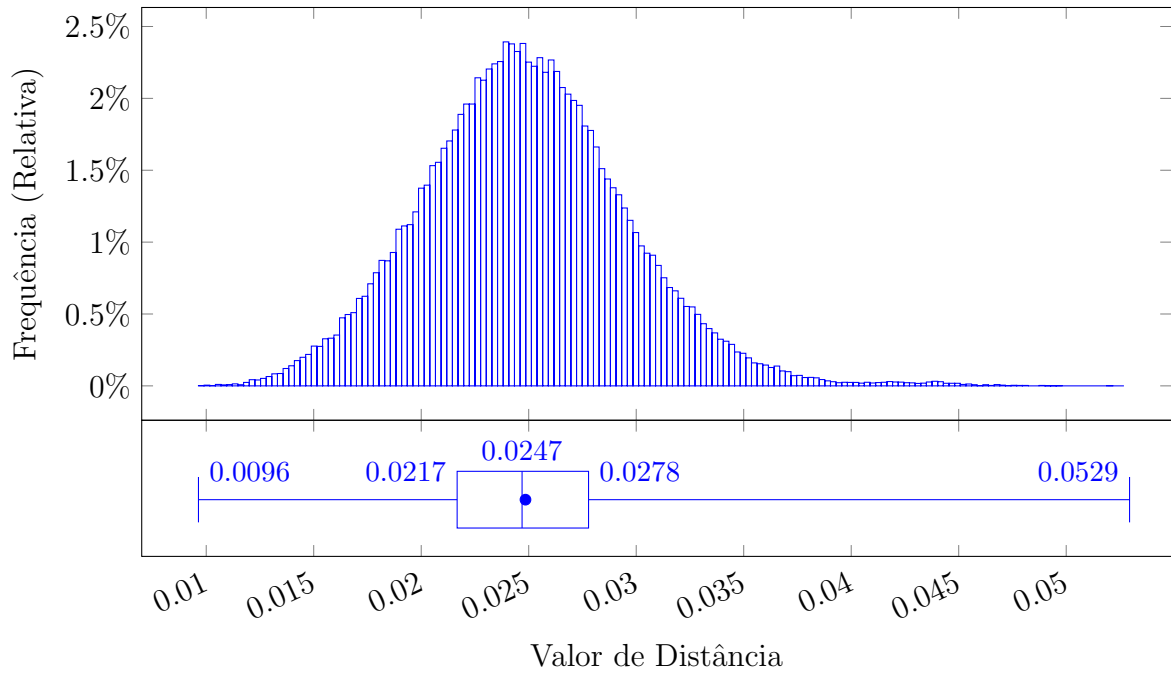
Figura 16 – Distribuição de Valores de Distância, sem Divisões por Rótulo



A.2 Por Rótulo de Gênero


A distribuição de valores de distância por rótulo “Masculino” possui média de 0.02484 e desvio padrão de 0.00477 unidades de distância, como visualizada na figura 17.

Figura 17 – Distribuição de Valores de Distância, por Rótulo “Masculino”



A distribuição de valores de distância por rótulo “Feminino” possui média de 0.025 e desvio padrão de 0.00427 unidades de distância, como visualizada na figura 18.

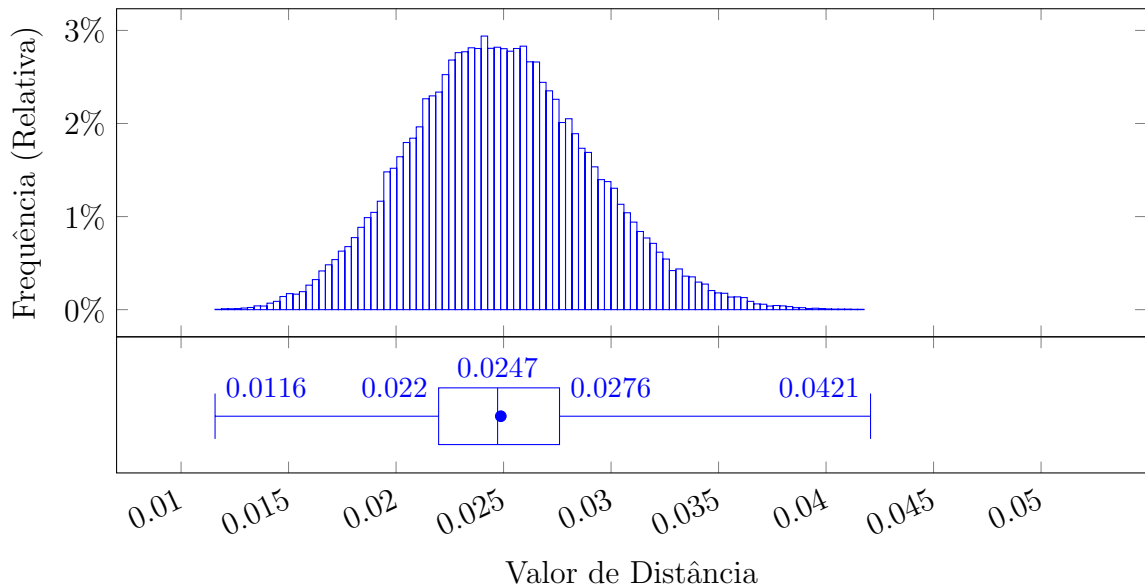
Figura 18 – Distribuição de Valores de Distância, por Rótulo “Feminino”



A.3 Por Rótulo de Idade


A distribuição de valores de distância por rótulo de idade entre 20 e 29 anos possui média de 0.02487 e desvio padrão de 0.00418 unidades de distância, como visualizada na figura 19.

Figura 19 – Distribuição de Valores de Distância, por Rótulo de Idade Entre 20 e 29 Anos



A distribuição de valores de distância por rótulo de idade entre 30 e 39 anos possui média de 0.02447 e desvio padrão de 0.00445 unidades de distância, como visualizada na figura 20.

Figura 20 – Distribuição de Valores de Distância, por Rótulo de Idade Entre 30 e 39 Anos



A distribuição de valores de distância por rótulo de idade entre 40 e 49 anos possui média de 0.02484 e desvio padrão de 0.00472 unidades de distância, como visualizada na figura 21.

A distribuição de valores de distância por rótulo de idade entre 50 e 59 anos possui média de 0.02621 e desvio padrão de 0.00475 unidades de distância, como visualizada na figura 22.

Figura 21 – Distribuição de Valores de Distância, por Rótulo de Idade Entre 40 e 49 Anos

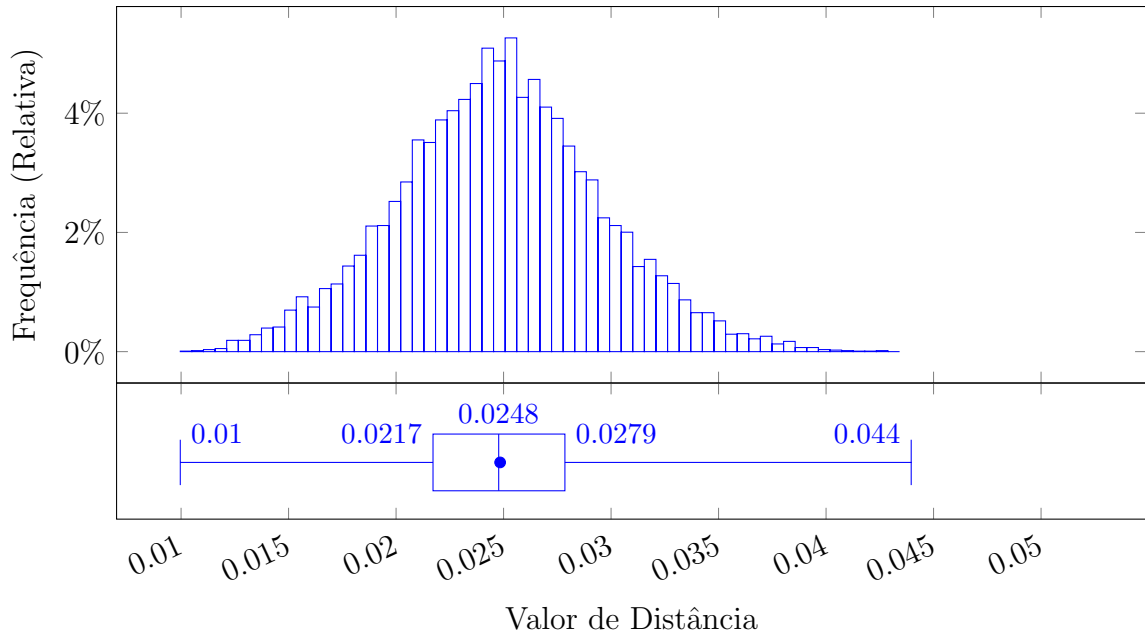

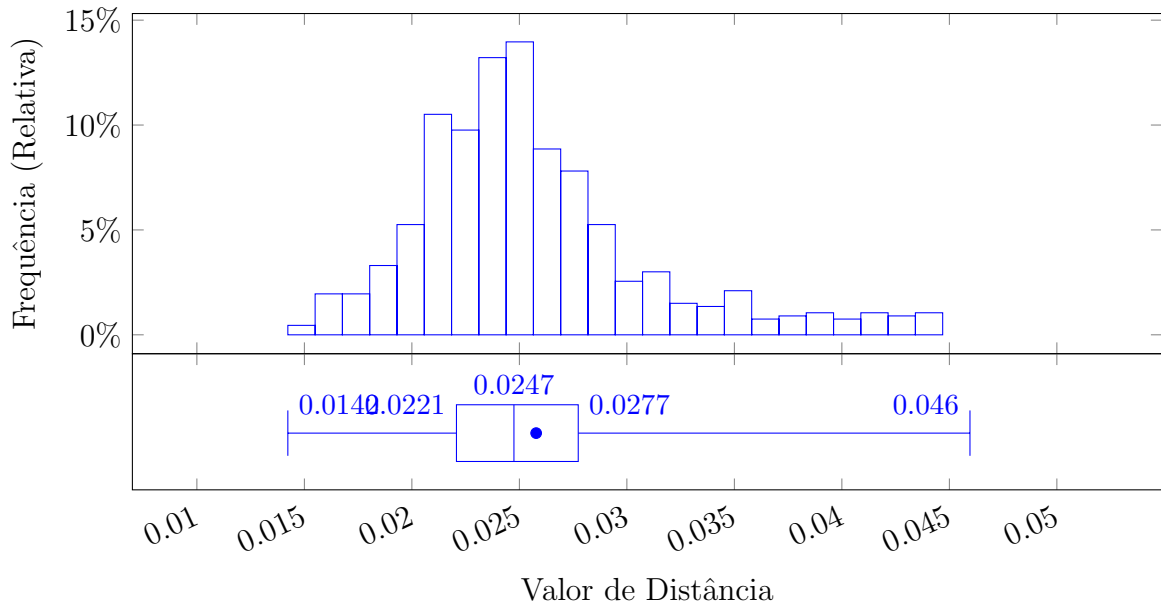


Figura 22 – Distribuição de Valores de Distância, por Rótulo de Idade Entre 50 e 59 Anos



A distribuição de valores de distância por rótulo de idade de 60 anos ou mais possui média de 0.02578 e desvio padrão de 0.00581 unidades de distância, como visualizada na figura 23.


Figura 23 – Distribuição de Valores de Distância, por Rótulo de Idade de 60 Anos ou Mais



A.4 Por Rótulo de Raça


A distribuição de valores de distância por rótulo “Branco” possui média de 0.02454 e desvio padrão de 0.0431 unidades de distância, como visualizada na figura 24.

Figura 24 – Distribuição de Valores de Distância, por Rótulo “Branco”




A distribuição de valores de distância por rótulo “Latino/Hispânico” possui média de 0.02514 e desvio padrão de 0.00443 unidades de distância, como visualizada na figura 25.

Figura 25 – Distribuição de Valores de Distância, por Rótulo “Latino/Hispânico”



A distribuição de valores de distância por rótulo “Indiana” possui média de 0.02453 e desvio padrão de 0.00447 unidades de distância, como visualizada na figura 26.


Figura 26 – Distribuição de Valores de Distância, por Rótulo “Indiana”



A distribuição de valores de distância por rótulo “Leste Asiática” possui média de


0.02538 e desvio padrão de 0.00452 unidades de distância, como visualizada na figura 27.

Figura 27 – Distribuição de Valores de Distância, por Rótulo “Leste Asiática”



A distribuição de valores de distância por rótulo “Negro” possui média de 0.02448 e desvio padrão de 0.00459 unidades de distância, como visualizada na figura 28.

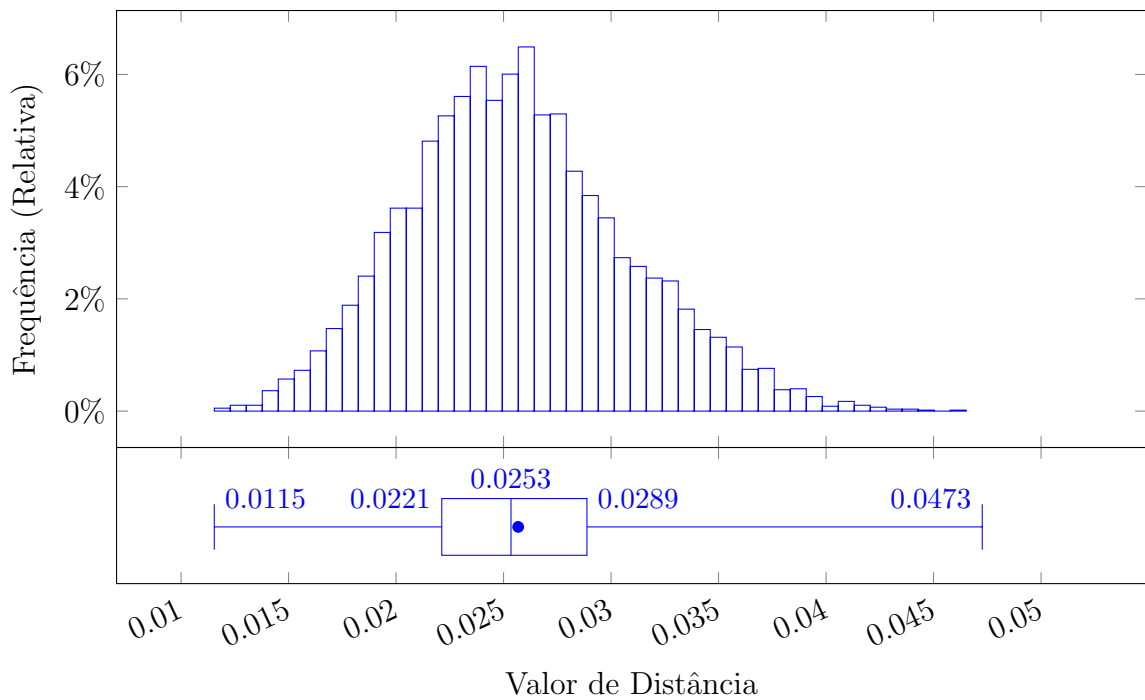
Figura 28 – Distribuição de Valores de Distância, por Rótulo “Negro”



A distribuição de valores de distância por rótulo “Sudeste Asiática” possui média de


0.02567 e desvio padrão de 0.00515 unidades de distância, como visualizada na figura 29.

Figura 29 – Distribuição de Valores de Distância, por Rótulo de “Sudeste Asiática”



A distribuição de valores de distância por rótulo "Oriente Médio" possui média de 0.02508 e desvio padrão de 0.0044 unidades de distância, como visualizada na figura 30.

Figura 30 – Distribuição de Valores de Distância, por Rótulo “Oriente Médio”



B DESVIOS DA TAXA DE FALSOS POSITIVOS

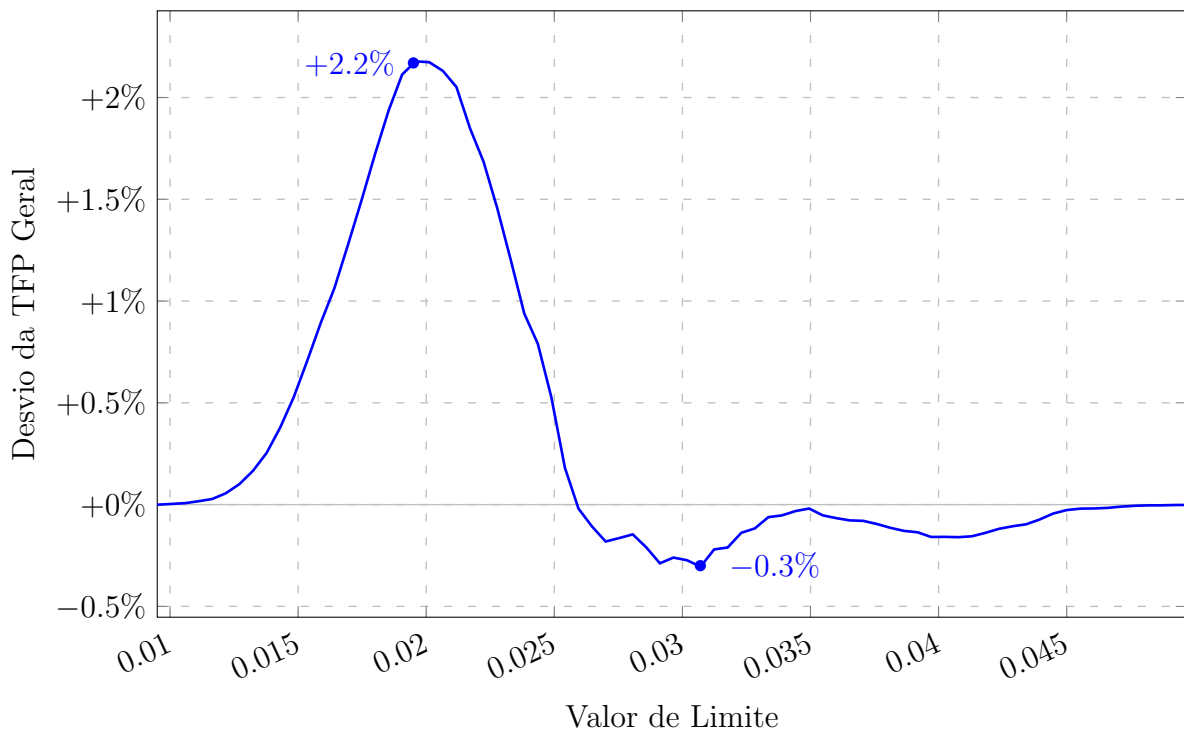
Como parte do procedimento de avaliação descrito na seção 4.2 foram coletadas as distribuições dos valores de distância entre pares de multi-descritores distintos para serem visualizados durante o processo de análise.

Sobre estas distribuições, é efetuado o cálculo da taxa de falsos positivos para valores de limite diferentes, o desvio das curvas obtidas em relação a TFP do conjunto completo é traçado, individualmente, nas seções a seguir.

B.1 Por Rótulo de Gênero

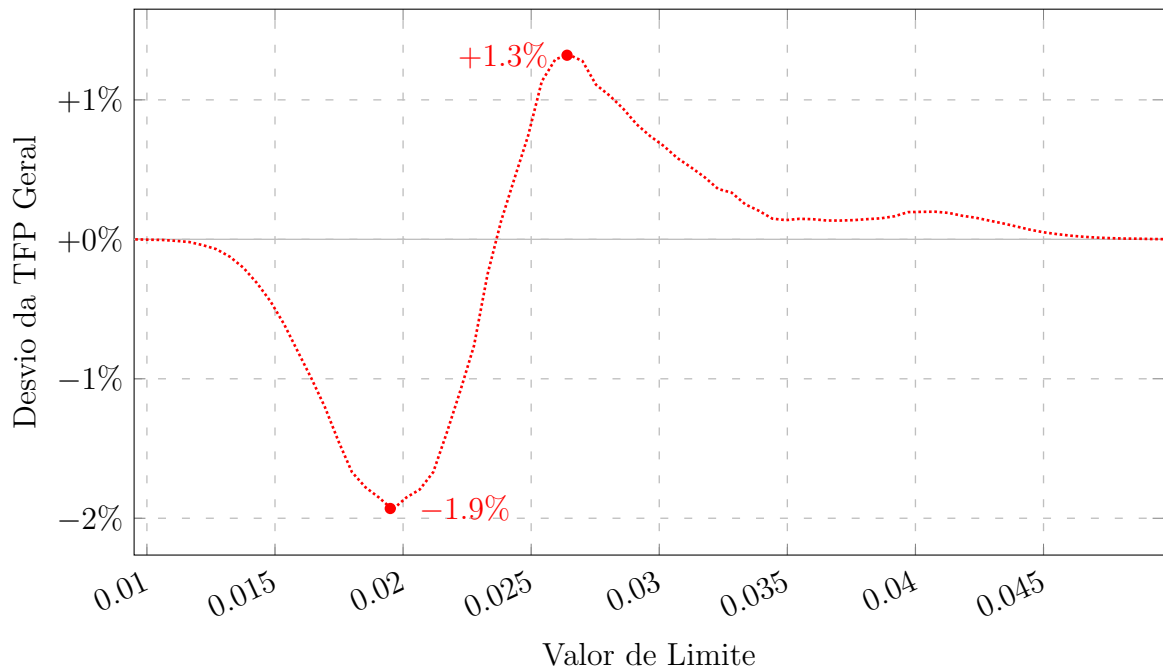
A taxa de falsos positivos para valores de limite diferentes sobre a distribuição de valores de distância por rótulo “Masculino”, subtraída da curva da TFP para o conjunto completo, pode ser visualizada na figura 31.

Figura 31 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo “Masculino”



A taxa de falsos positivos para valores de limite diferentes sobre a distribuição de valores de distância por rótulo “Feminino”, subtraída da curva da TFP para o conjunto completo, pode ser visualizada na figura 32.

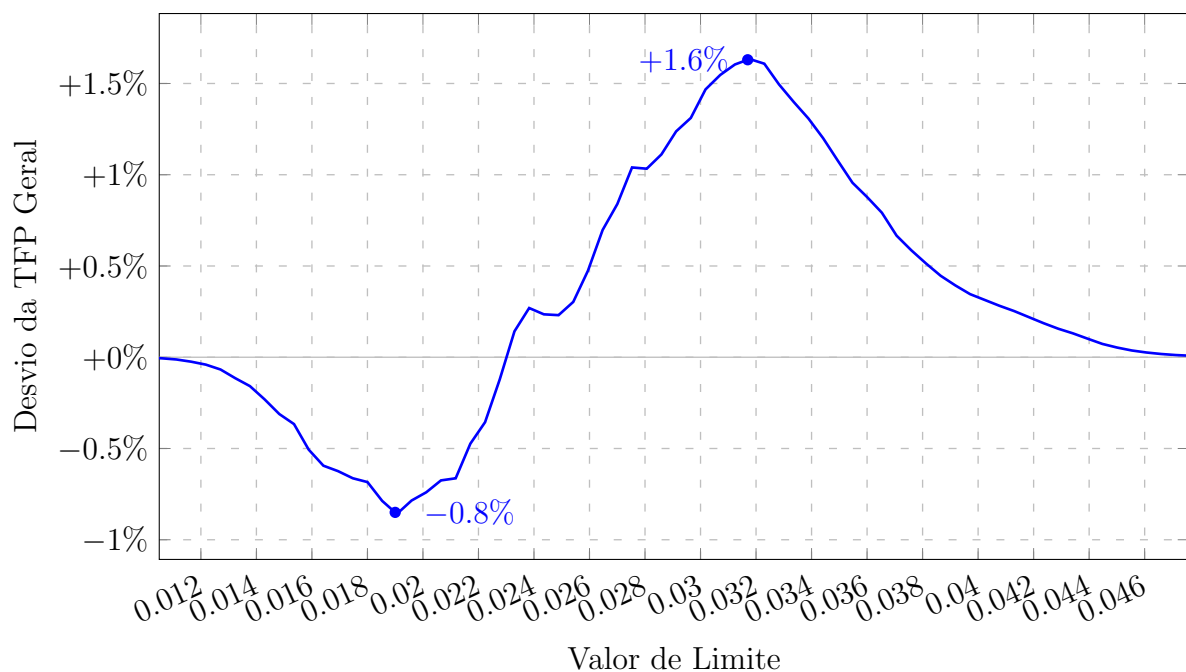
Figura 32 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo “Feminino”



B.2 Por Rótulo de Idade


A taxa de falsos positivos para valores de limite diferentes sobre a distribuição de valores de distância por rótulo de idade entre 20 e 29 anos, subtraída da curva da TFP para o conjunto completo, pode ser visualizada na figura 33.

Figura 33 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo de Idade Entre 20 e 29 Anos



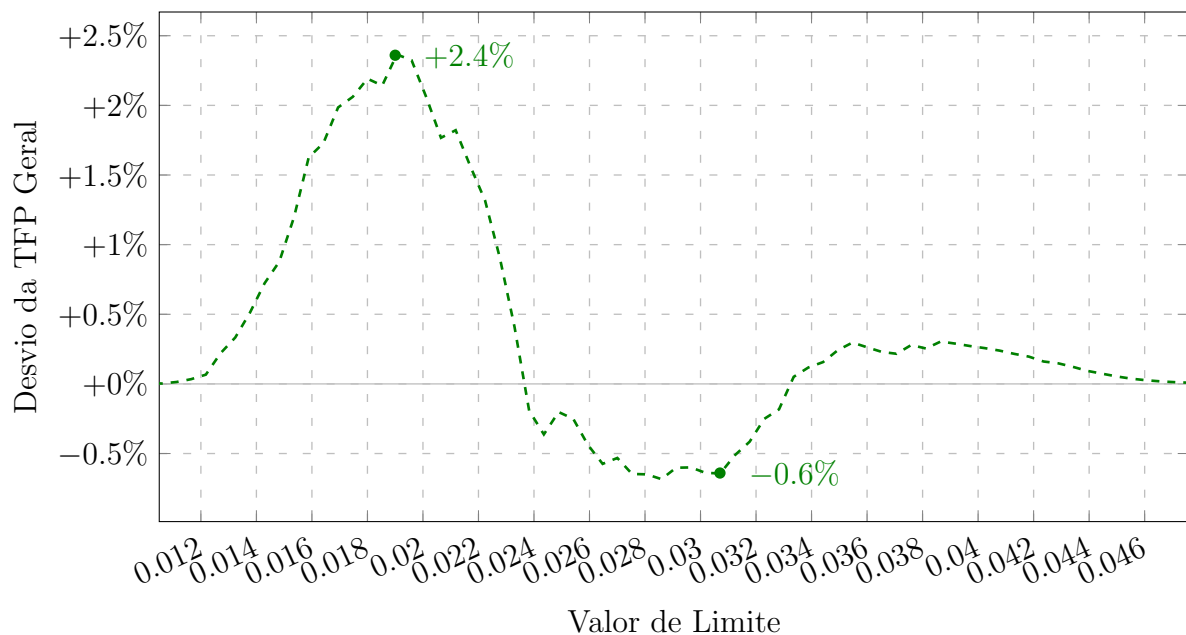
A taxa de falsos positivos para valores de limite diferentes sobre a distribuição de valores de distância por rótulo de idade entre 30 e 39 anos, subtraída da curva da TFP para o conjunto completo, pode ser visualizada na figura 34.

Figura 34 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo de Idade Entre 30 e 39 Anos



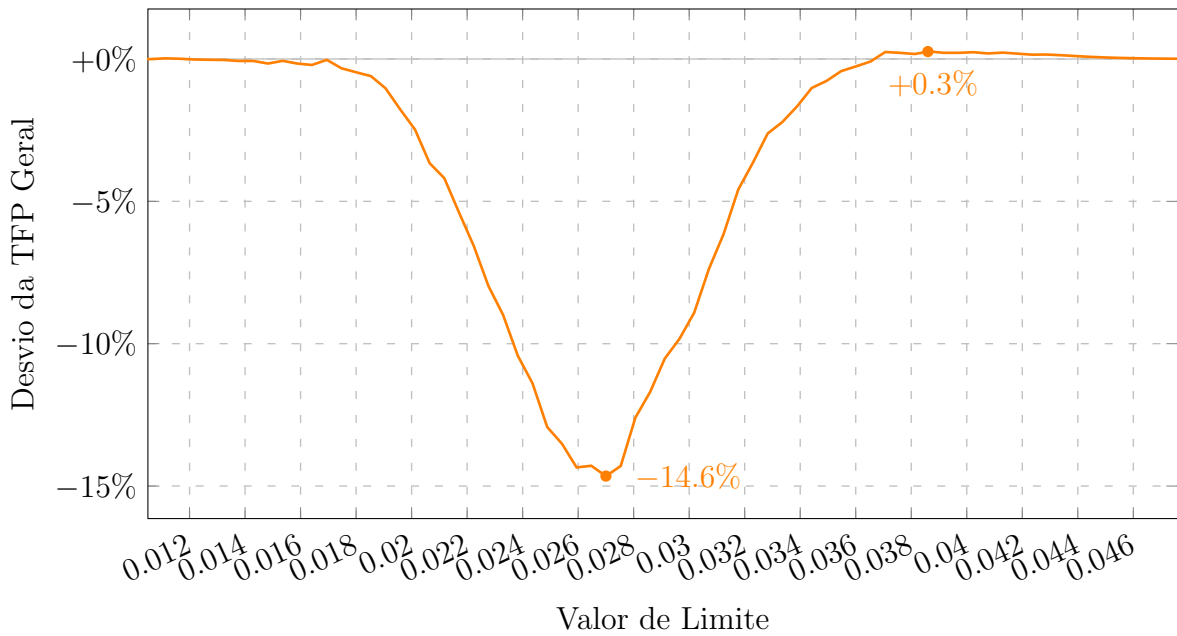
A taxa de falsos positivos para valores de limite diferentes sobre a distribuição de valores de distância por rótulo de idade entre 40 e 49 anos, subtraída da curva da TFP para o conjunto completo, pode ser visualizada na figura 35.

Figura 35 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo de Idade Entre 40 e 49 Anos



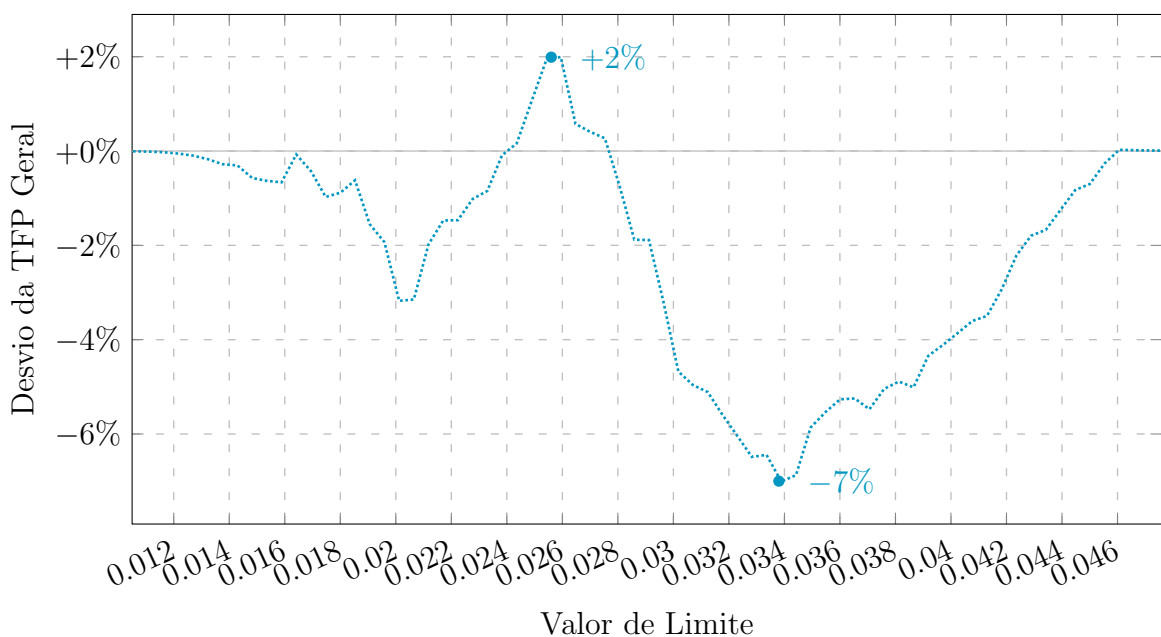
A taxa de falsos positivos para valores de limite diferentes sobre a distribuição de valores de distância por rótulo de idade entre 50 e 59 anos, subtraída da curva da TFP para o conjunto completo, pode ser visualizada na figura 36.

Figura 36 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo de Idade Entre 50 e 59 Anos



A taxa de falsos positivos para valores de limite diferentes sobre a distribuição de valores de distância por rótulo de idade de 60 anos ou mais, subtraída da curva da TFP para o conjunto completo, pode ser visualizada na figura 37.


Figura 37 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo de Idade de 60 Anos ou Mais



B.3 Por Rótulo de Raça


A taxa de falsos positivos para valores de limite diferentes sobre a distribuição de valores de distância por rótulo “Branco”, subtraída da curva da TFP para o conjunto completo, pode ser visualizada na figura 38.

Figura 38 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo “Branco”



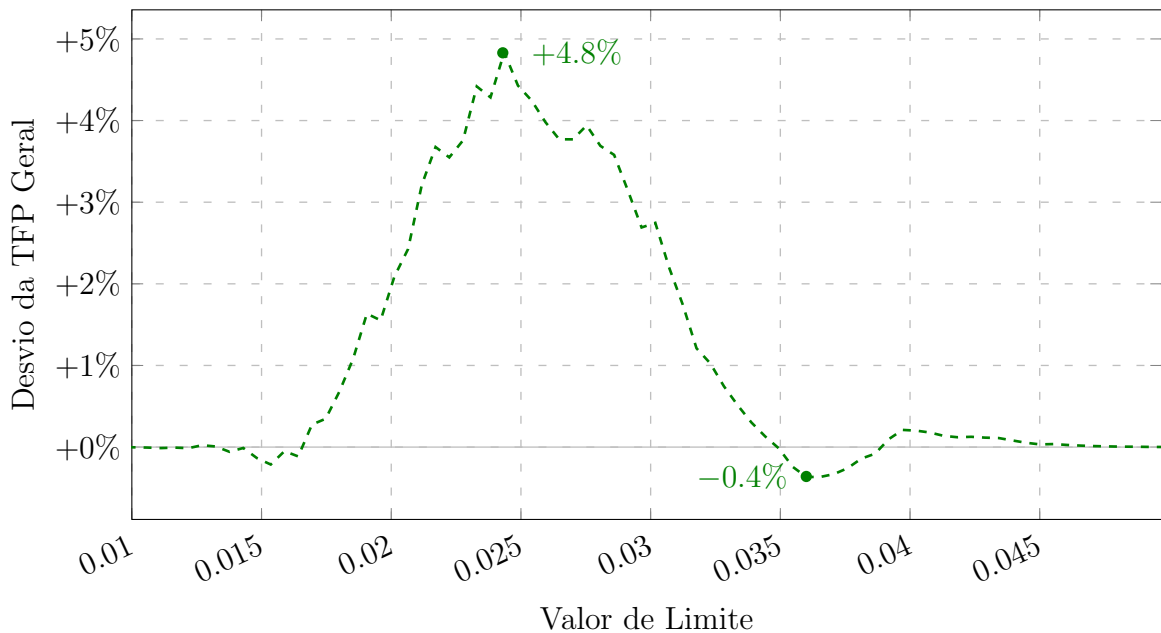
A taxa de falsos positivos para valores de limite diferentes sobre a distribuição de valores de distância por rótulo “Latino/Hispanico”, subtraída da curva da TFP para o conjunto completo, pode ser visualizada na figura 39.

Figura 39 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo “Latino/Hispanico”




A taxa de falsos positivos para valores de limite diferentes sobre a distribuição de valores de distância por rótulo “Indiana”, subtraída da curva da TFP para o conjunto completo, pode ser visualizada na figura 40.

Figura 40 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo “Indiana”



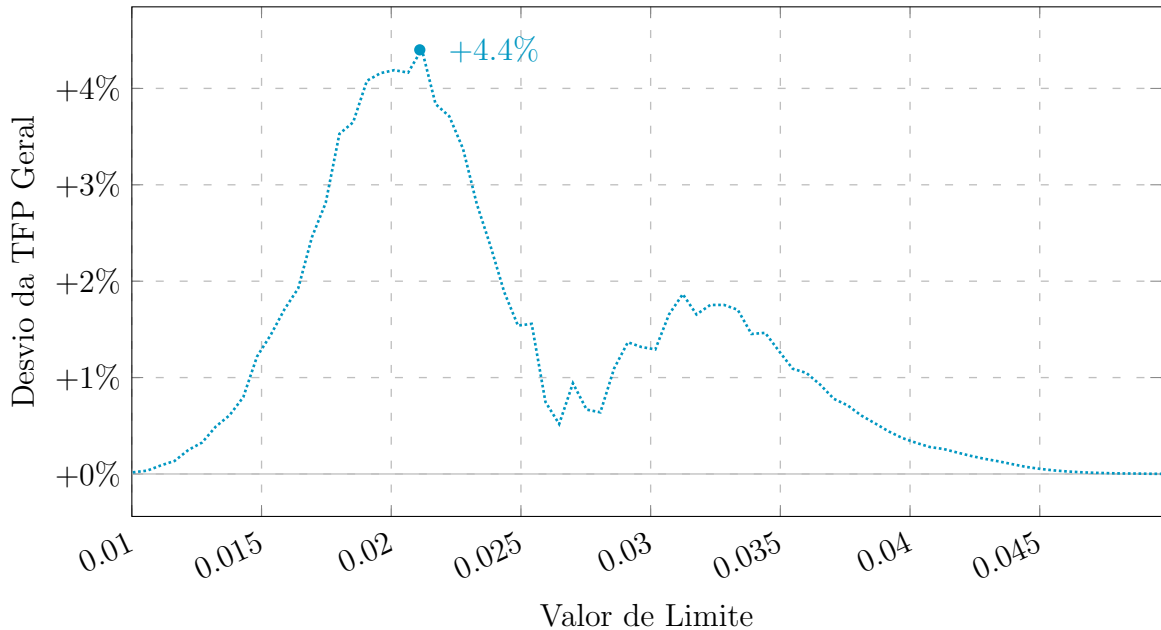
A taxa de falsos positivos para valores de limite diferentes sobre a distribuição de valores de distância por rótulo “Leste Asiática”, subtraída da curva da TFP para o conjunto completo, pode ser visualizada na figura 41.

Figura 41 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo “Leste Asiática”




A taxa de falsos positivos para valores de limite diferentes sobre a distribuição de valores de distância por rótulo “Negro”, subtraída da curva da TFP para o conjunto completo, pode ser visualizada na figura 42.

Figura 42 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo “Negro”



A taxa de falsos positivos para valores de limite diferentes sobre a distribuição de valores de distância por rótulo “Sudeste Asiática”, subtraída da curva da TFP para o conjunto completo, pode ser visualizada na figura 43.

Figura 43 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo “Sudeste Asiática”



A taxa de falsos positivos para valores de limite diferentes sobre a distribuição de valores de distância por rótulo “Oriente Médio”, subtraída da curva da TFP para o conjunto completo, pode ser visualizada na figura 44.

Figura 44 – Desvio da Taxa de Falsos Positivos sobre Valores de Limite, por Rótulo “Oriente Médio”

