



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO DE CIÊNCIAS DA EDUCAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA INFORMAÇÃO

Guilherme Birckan

**MÉTODO DE AVALIAÇÃO DE FERRAMENTAS DE RECONHECIMENTO
FACIAL DE CÓDIGO ABERTO NO CONTEXTO DA SEGURANÇA PÚBLICA**

Florianópolis

2020

Guilherme Birckan

**MÉTODO DE AVALIAÇÃO DE FERRAMENTAS DE RECONHECIMENTO
FACIAL DE CÓDIGO ABERTO NO CONTEXTO DA SEGURANÇA PÚBLICA**

Dissertação submetida ao Programa de Pós-Graduação
em Ciência da Informação da Universidade Federal de
Santa Catarina para a obtenção do título de Mestre em
Ciência da Informação

Linha de Pesquisa: Informação, Gestão e Tecnologia

Eixo: Informação e tecnologia

Orientador: Prof. Dr. Angel Freddy Godoy Viera

Florianópolis

2020

Ficha de identificação da obra

Birckan, Guilherme

MÉTODO DE AVALIAÇÃO DE FERRAMENTAS DE RECONHECIMENTO FACIAL DE CÓDIGO ABERTO NO CONTEXTO DA SEGURANÇA PÚBLICA /Guilherme Birckan; orientador, Angel Freddy Godoy Viera, 2020.

78 p.

Dissertação (mestrado) - Universidade Federal de Santa Catarina, Centro de Ciências da Educação, Programa de Pós-Graduação em Ciência da Informação, Florianópolis, 2020.

Inclui referências.

1. Ciência da Informação. 2. Reconhecimento facial. 3. Segurança pública. 4. Aprendizado de máquina. I. Godoy Viera, Angel Freddy. II. Universidade Federal de Santa Catarina. Programa de Pós-Graduação em Ciência da Informação. III. Título.

Guilherme Birckan

**MÉTODO DE AVALIAÇÃO DE FERRAMENTAS DE RECONHECIMENTO
FACIAL DE CÓDIGO ABERTO NO CONTEXTO DA SEGURANÇA PÚBLICA**

O presente trabalho em nível de mestrado foi avaliado e aprovado por banca examinadora composta pelos seguintes membros:

Prof. Dr. Douglas Dyllon Jerônimo de Macedo
Universidade Federal de Santa Catarina

Prof. Dr. Edberto Fereda
Universidade Estadual Paulista

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi julgado adequado para obtenção do título de Mestre em Ciência da Informação.

Prof. Dr. Adilson Luiz Pinto
Coordenador do Programa de Pós-Graduação

Prof. Dr. Angel Freddy Godoy Viera
Orientador

Florianópolis, 2020

Este trabalho é dedicado aos meus queridos pais.

RESUMO

O presente trabalho tem por objetivo descrever o processo construtivo e os resultados da proposição e experimentação de um método de avaliação de ferramentas de reconhecimento facial de código aberto voltado às características dos conjuntos de imagens de identificação de indivíduos mantidos pela Polícia Federal, visando robustecer suas investigações e suas atividades de polícia judiciária e administrativa. Para tanto, foi analisado, por meio de uma revisão bibliográfica sistemática, o estado da arte dos algoritmos e soluções publicadas na literatura científica, tendo sido constatado um predomínio do uso de redes neurais convolucionais. O método proposto se baseia na construção de um conjunto de fotos conhecidas e de um conjunto de imagens de desconhecidos, extraídas de ambiente não controlado (redes sociais); execução de algoritmos de reconhecimento facial no qual são cruzados os conjuntos de dados na tentativa de estabelecer identidades para os indivíduos incógnitos, e por fim compilação e plotagem dos resultados com base nas acurácias encontradas. Utilizando-se desse procedimento, foram realizados ensaios de acurácia em três frameworks: VGG-Face (Visual Geometry Group da Universidade de Oxford), FaceNet e VIPLFaceNet (Visual Information Processing and Learning Group do Chinese Academy of Sciences), tendo os dois últimos apresentado os melhores resultados. Os experimentos demonstraram que as precisões atuais das ferramentas open source de reconhecimento facial são passíveis de aproveitamento para as atividades da Polícia Federal, restando como oportunidade futura o efetivo desenvolvimento e/ou a aquisição de software capaz de processar os dados disponíveis, e o método proposto, como balizador das alternativas.

Palavras-chave: Reconhecimento facial. Segurança pública. Redes neurais. Aprendizado de máquina.

ABSTRACT

This paper describes the process of constructing and experimenting with a method for the evaluation of open source face recognition tools aimed at image identification datasets maintained by the Brazilian Federal Police, in order to strengthen their investigations and administrative/judiciary duties. Therefore, the state of the art of published algorithms and systems was evaluated by a systemic literature review, where it was observed the trend of convolutional neural networks usage. The proposed method is based on the compilation of two datasets, one of photos of known identities, and another extracted from unconstrained sources such as social networks; the execution of face recognition algorithms where both datasets are crossed for identity predictions of the unknown subjects, and, at last, the plotting of the results. Based on the proposed method, three frameworks were tested for accuracy scores: VGG-Face (Visual Geometry Group from Oxford University), FaceNet and VIPLFaceNet (Visual Information Processing and Learning Group from the Chinese Academy of Sciences), where the last two achieved the best outcomes. Experiments demonstrated that modern open source face recognition tools precisions allow their application for the assignments of the Federal Police, whereas future opportunities lie on the development and/or the acquisition of software capable of processing in-house available data, while the method can be used for benchmarking the alternatives.

Keywords: Face recognition; Law enforcement; Neural networks; Machine learning.

LISTA DE FIGURAS

Figura 1 - Uma rede neural multicamada com uma primeira camada de entrada ($k=0$), duas camadas ocultas ($k=1, k=2$) e uma camada de saída ($k=3$).	22
Figura 2 - Uma taxonomia de arquiteturas de redes neurais <i>feed-forward</i> e recorrentes/ <i>feedback</i>	23
Figura 3 - Exemplo de arquitetura de uma rede neural convolucional com camadas totalmente conectadas.....	26
Figura 4 - Processos de aprendizado distintos entre o <i>machine learning</i> tradicional e o <i>transfer learning</i>	27
Figura 5 - Blocos de construção de um sistema de reconhecimento facial.	28
Figura 6 - Dinâmica de funcionamento do framework de detecção de faces MTCNN.	29
Figura 7 - Modelo de aprendizado utilizado pelo Triplet Loss.	30
Figura 8 - Ilustração das camadas da rede neural profunda utilizada pelo VGG-Face.	31
Figura 9 - Amostras das fotografias utilizadas no dataset de treinamento do VGG-Face.....	31
Figura 10 - Estrutura da solução FaceNet.	33
Figura 11 - Exemplo de normalização de um rosto utilizando 5 pontos.	33
Figura 12 - Evolução de técnicas de reconhecimento facial no <i>dataset</i> LFW.	44
Figura 13 - Arquivo “84953187172.jpg”.	47
Figura 14 - Arquivo “30967859883.jpg”.	48
Figura 15 - Arquivo “1145792022.jpg”.	48
Figura 16 - Imagem obtida de rede social, inserida no <i>dataset</i> de prospectos.	49
Figura 17 - Imagem obtida de rede social, inserida no <i>dataset</i> de prospectos.	49
Figura 18 - <i>Thumbnails</i> (miniaturas) de outras imagens obtidas de rede social, inseridas no <i>dataset</i> de prospectos.....	49
Figura 19 - Faixas etárias do <i>dataset</i> de prospectos.	50
Figura 20 - Ilustração de uma curva CMC de desempenho.	51
Figura 21 - Fluxograma de execução do método de avaliação.....	55
Figura 22 - Representação gráfica dos resultados compilados.....	58

LISTA DE QUADROS

Quadro 1 - Sumarização da caracterização da pesquisa.....	35
Quadro 2 - Critérios de inclusão de publicações na pesquisa: bases, disciplinas, campos e palavras-chave escolhidas.....	37
Quadro 3 - Critérios utilizados para a exclusão dos artigos da revisão.....	37
Quadro 4 - Trabalhos analisados depois de aplicados os critérios de inclusão e exclusão.	38
Quadro 5 - Características comuns aos trabalhos analisados.	44
Quadro 6 - Tempos de execução aproximados dos ensaios.	56
Quadro 7 - Resultados Encontrados para 250 prospectos.	57

LISTA DE ABREVIATURAS E SIGLAS

ART	Adaptive Resonance Theory é uma teoria de aspectos sobre como o cérebro processa informações.
BSD	Berkeley Software Distribution é uma licença de código aberto.
CNN	Convolutional Neural Network, classe de rede neural comumente utilizada no processamento de imagens.
CuDNN	Biblioteca acelerada por GPUs e otimizada para o uso em redes neurais profundas.
FRGC	Face Recognition Grand Challenge é um conjunto de fotografias de pessoas.
GPU	Graphics Processing Unit é um tipo de processador especializado em processar gráficos.
LBA	Local Binary Patterns são um tipo de descritor visual usado para classificações em visão computacional.
LDA	Linear Discriminant Analysis é um método utilizado em estatística, reconhecimento de padrões e aprendizado de máquina para encontrar uma combinação linear de características que unam ou separem duas ou mais classes de objetos.
LFW	Labeled Faces in the Wild é um conjunto de fotografias de rostos comumente utilizado para estudos relacionados ao reconhecimento facial em ambiente não controlado.
MOBIO	Conjunto de dados contendo áudio e vídeo de 152 pessoas, mantido pelo Idiap Research Institute.
MS-celeb-1M	Microsoft Celeb é um conjunto de 10 milhões de imagens de faces obtidas a partir da Internet e publicado em 2016 pela Microsoft Research.
OCR	Object Character Recognition é uma tecnologia para reconhecer caracteres a partir de um arquivo de imagem ou mapa de <i>bits</i> , sejam eles escaneados, escritos a mão, datilografados ou impressos.
ORL	Conjunto de 10 imagens de rostos de 40 sujeitos distintos construído pelo Laboratório AT&T Laboratories Cambridge.
PCA	Principal Component Analysis é um procedimento matemático que utiliza uma transformação ortogonal (ortogonalização de vetores) para converter um conjunto de observações de variáveis possivelmente correlacionadas num conjunto de valores de variáveis linearmente não correlacionadas chamadas de componentes principais.
RBF	Radial Basis Function é uma função sobre números reais cujos valores dependem da distância a partir da origem.
RNA	Rede Neural Artificial é um modelo computacional inspirado pelo sistema nervoso central de um animal (em particular o cérebro), capaz de realizar aprendizado de máquina e reconhecimento de padrões.
ROS	Robot Operating System é uma coleção de <i>frameworks</i> de <i>software</i> para desenvolvimento de robôs, que fornece a funcionalidade de um sistema operacional em um <i>cluster</i> de computadores heterogêneo.
SDK	Software Development Kit é tipicamente um conjunto de ferramentas de desenvolvimento de <i>software</i> que permite a criação de aplicativos.
SOM	Self-Organizing Map é um tipo de rede neural artificial treinada usando aprendizado não-supervisionado.

SUMÁRIO

1	INTRODUÇÃO	13
1.1	PROBLEMA DE PESQUISA E MOTIVAÇÃO	14
1.2	QUESTÃO DE PESQUISA	14
1.3	JUSTIFICATIVA	15
1.4	OBJETIVOS	17
1.4.1	Objetivo Geral.....	17
1.4.2	Objetivos Específicos	17
1.5	ESTRUTURA DA DISSERTAÇÃO	18
2	FUNDAMENTAÇÃO TEÓRICA.....	19
2.1	APRENDIZADO DE MÁQUINA (<i>MACHINE LEARNING</i>).....	19
2.2	REDES NEURAIS ARTIFICIAIS	21
2.2.1	Deep learning	24
2.2.2	Redes Neurais Convolucionais	25
2.3	TRANSFER LEARNING	26
2.4	SISTEMAS DE RECONHECIMENTO FACIAL	28
2.4.1	VGG-Face.....	31
2.4.2	FaceNet	32
2.4.3	VIPLFaceNet.....	33
3	PROCEDIMENTOS METODOLÓGICOS.....	35
3.1	CARACTERIZAÇÃO DA PESQUISA	35
3.2	REVISÃO SISTEMÁTICA DA LITERATURA.....	36
3.3	ELABORAÇÃO E EXECUÇÃO DO MÉTODO DE AVALIAÇÃO.....	45
3.3.1	PROPOSTA DE MÉTODO.....	45
<i>3.3.1.1</i>	<i>Seleção das tecnologias de reconhecimento facial</i>	<i>46</i>
<i>3.3.1.2</i>	<i>Construção dos datasets.....</i>	<i>47</i>

3.3.1.2.1	Galeria (<i>dataset</i>) de identidades conhecidas.....	47
3.3.1.2.2	Conjunto de prospectos (<i>dataset</i> de candidatos desconhecidos)	48
3.3.1.3	<i>Metodologia para avaliação de resultados</i>	50
3.4	PROTOTIPAÇÃO	51
3.4.1	VGG-Face	52
3.4.2	FaceNet	52
3.4.3	VIPLFaceNet	53
3.5	RESULTADOS	54
4	CONCLUSÃO	60
	REFERÊNCIAS	62
	APÊNDICE A – Código-fonte do ensaio com VGG-Face	67
	APÊNDICE B – Código-fonte do ensaio com FaceNet	68
	APÊNDICE C – Código-fonte do ensaio com VIPLFaceNet	70
	APÊNDICE D – Trabalhos excluídos na revisão de literatura	71
	ANEXO A – Autorização de uso de imagens de passaportes	78

1 INTRODUÇÃO

A visão computacional (*computer vision*) é uma disciplina que estuda a extração de informações a partir de imagens, buscando automatizar as funções do olho humano. Dentre as inúmeras aplicações práticas do reconhecimento de imagens e de vídeos, o reconhecimento facial tem recebido crescente foco, à medida que seus resultados têm atingido patamares seguros de confiabilidade. Para o uso nesta aplicação, tem-se cada vez mais adotado ferramentas baseadas em aprendizado de máquina (*machine learning*), esta última uma área da ciência da computação que emergiu do campo da inteligência artificial, evoluindo a partir do reconhecimento de padrões.

Aplicações típicas do reconhecimento facial incluem os setores do entretenimento (*video games* e realidade virtual), *marketing* (análise de humor, reações e sentimentos), educação (programas de ensino interativos), *smart cards* (documentos pessoais e de identificação), segurança da informação (controles de acesso e de frequência, autenticação e autorização de sistemas, criptografia de arquivos), e segurança pública (vigilância eletrônica, investigações, identificação de suspeitos).

O amadurecimento dos algoritmos de reconhecimento facial é palpável e explícito, uma vez que a maioria dos trabalhos contemporâneos se serve de *benchmarks* padronizados, permitindo-se assim a constatação de seus aperfeiçoamentos. Para efeitos comparativos e de avaliação de resultados, tanto a comunidade acadêmica como a iniciativa privada usualmente utilizam *datasets* públicos, em especial a FERET *database* (Face Recognition Technology) e a Labeled Faces in the Wild (LFW). Ambos *datasets* possuem múltiplas imagens de indivíduos conhecidos (rotulados) para fins de treinamento e testes dos algoritmos, tendo sido suas fotografias capturadas em condições diversas de luminosidade, angulação, expressão facial, e uso de acessórios (óculos, penteado, barba etc).

Diferentemente do reconhecimento para fins comerciais, citando-se como exemplo a fatura de imagens de uma mesma pessoa disponível nas plataformas de redes sociais, no âmbito da segurança pública, comumente as autoridades possuem de início apenas uma única figura de um cidadão para fins de alimentação de bases de dados, processamento e aprendizado sistêmico. Tal registro tende a ser originário de um retrato frontal obtido quando da emissão de um documento de segurança, tal qual um passaporte, título de eleitor, ou carteira nacional de habilitação.

Assim sendo, enquanto o desenvolvimento das tecnologias de reconhecimento facial proporcionou a criação de inúmeras aplicações voltadas principalmente à iniciativa privada, valendo-se da riqueza e robustecimento das fotografias, muitos órgãos públicos, especialmente os brasileiros, permaneceram alheios (ou atrasados) a essa evolução, podendo-se argumentar tanto a falta de investimentos como falta de conhecimento quanto à efetividade das soluções. É possível afirmar, desta feita, que existe uma imensa massa documental de imagens de pessoas que resta inerte em conjuntos de dados governamentais, passivamente aguardando aproveitamento, podendo ser resgatada para alimentação de sistemas de identificação criminais e apoio investigativo.

1.1 PROBLEMA DE PESQUISA E MOTIVAÇÃO

O panorama apresentado é comum aos *datasets* de imagens de pessoas mantidos por órgãos de segurança pública e/ou governamentais: fotografias frontais singulares na ordem dos milhões de indivíduos, pendentes de melhor aproveitamento. O problema reside na insuficiência (ou até mesmo inexistência) de métodos de comparação de tecnologias de reconhecimento facial aplicáveis a esse contexto. A consolidação de um método efetivo proporcionará ao poder público elucidar se as ferramentas disponíveis (identificadas em etapas de levantamento bibliográfico e de revisão da literatura), sob o ponto de vista da acurácia dos algoritmos e *frameworks* existentes, são passíveis de utilização para a implementação de protótipo (ou aquisição de *software*) de reconhecimento facial voltado às características das bases de imagens da Polícia Federal.

Desta feita, o escopo do presente trabalho é a proposição de um método de avaliação de ferramentas nesse contexto, o qual deverá englobar a construção de conjuntos de dados, a execução de testes de predição de identidades, e um comparativo utilizando-se de métricas de aferição de resultados.

1.2 QUESTÃO DE PESQUISA

Dada a necessidade de robustecer as investigações policiais e auxiliar as ações da Polícia Federal, aproveitando-se da dimensão de imagens de indivíduos disponíveis tanto em conjuntos de dados proprietários como aqueles obtidos por meio de convênios e aqueles extraídos de fontes públicas e/ou redes sociais, a questão de pesquisa é proposta da seguinte

forma: que método pode ser utilizado para a avaliação de ferramentas de reconhecimento facial de código aberto no contexto de identificação de indivíduos a partir de fotografias de documentos?

Considerando o atual estado-da-arte das ferramentas construídas com este propósito e que implementam técnicas de aprendizado de máquina, a finalidade é a de cotejar a factibilidade do desenvolvimento de protótipo que apresente resultados úteis sobre uma base de dados de larga escala de fotografias de documentos de identificação de indivíduos. Por resultados úteis, entende-se a apresentação automatizada de possíveis identidades para uma imagem de um desconhecido obtida em ambiente não controlado (condições aleatórias de angulação, aproximação, luminosidade e plano de fundo).

1.3 JUSTIFICATIVA

Inexiste ferramenta atualmente em produção no âmbito da Polícia Federal para o processamento dos conjuntos de dados de fotografias de indivíduos oriundas de sistemas próprios, como o de confecção de passaportes ou o de registro de estrangeiros, e daquelas eventualmente obtidas pela celebração de convênios, como as imagens existentes no Registro Nacional de Carteira de Habilitação ou nos cadastros de eleitores da Justiça Eleitoral. Ocorrem diversos cenários no âmbito de investigações criminais onde há a captura de imagens de suspeitos (como por exemplo em câmeras de segurança ou em levantamentos nas redes sociais), porém não há forma de reconhecê-los, em virtude de não ter sido implantada tecnologia capaz de interligar os dados e inferir identidades.

O reconhecimento facial é apenas uma das aplicações possíveis para o aproveitamento de tamanha base de informações, mas de enorme utilidade no contexto da segurança pública. O virtual estabelecimento de um *software* capaz de consumir e de cruzar esses dados abre ainda a oportunidade da criação de sistemas subjugados, como a detecção de identidades múltiplas, revelação de pessoas perdidas, ou descobrimento de indivíduos de interesse em locais públicos de circulação, tais quais estações de transporte em massa ou sítios de grandes eventos.

Considerando que a amplitude dos trabalhos publicados utiliza, como *input*, *datasets* de fotografias múltiplas (e não de documentos de identificação), a proposição de um método para a comparação de algoritmos ou *frameworks* de código aberto sobre dados com as particularidades descritas será um acréscimo não só para a segurança pública, mas também para a comunidade científica.

Já a opção por soluções *open source* pode ser justificada tanto sob o prisma do custo operacional (ou diminuição dele), como da eventual dependência de um produto com algoritmos proprietários, cujo ciclo evolutivo e de atualizações restaria alheio de qualquer tipo de controle.

Estimada a população brasileira em mais de 208 milhões de habitantes (IBGE, 2018), também proporcionalmente continentais são as bases de dados de fotografias de documentos. Tal plethora documental, em virtude de sua variedade, volume, veracidade, valor e velocidade de crescimento, a depender do prisma utilizado, pode vir a ser considerada um exemplo de Big Data. Conforme enfatizam Provost e Fawcett (2013), a ciência de dados é o tecido que conecta as tecnologias de processamento de dados com a tomada de decisões baseada em informações.

Da mesma forma, a proposta de um estudo visando a evolução das ferramentas disponíveis aos órgãos governamentais (em especial de segurança pública) encontra respaldo no pensamento de Saracevic (1995), para quem a ligação inexorável com a tecnologia da informação é uma dentre as três características fundamentais da Ciência da Informação.

Assim também corrobora Le Coadic (1996), que afirma:

A Ciência da Informação é uma dessas novas interdisciplinas, um desses novos campos de conhecimentos onde colaboram entre si, principalmente, a psicologia, a linguística, a sociologia, a informática, a matemática, a lógica, a estatística, a eletrônica, a economia, o direito, a filosofia, a política e as telecomunicações. (p. 22-23)

Acrescenta ainda o autor diversos temas periféricos que se destacam, sendo pertinentes à pesquisa em tela, principalmente, as bases de dados, a recuperação da informação, os sistemas especialistas, e os algoritmos, refletindo-se, destarte, a relevância do presente estudo para a Ciência da Informação.

A temática da pesquisa se encaixa, com efeito, à recuperação da informação multimídia, que trata da busca por conhecimento em todas suas formas, em todos os lugares, conforme explicam Lew et al. (2006): de fato, de que adianta todo o conhecimento do mundo, se não é possível encontrar nada? Corroboram Meghini, Sebastiani e Straccia (2001), dizendo que a preocupação principal da recuperação da informação multimídia é facilmente expressa: dada uma coleção de documentos multimídia (tais como texto, imagens, vídeo e som), encontrar aqueles que possuem relevância frente às informações que o usuário necessita. Ainda nesse campo, Hanjalic et al. (2008) definem a recuperação da informação multimídia como o conjunto de teorias, algoritmos e sistemas que têm por objetivo a extração de descritores pertinentes ou

de metadados relacionados a conteúdo multimídia, permitindo a busca, a recuperação, e demais funções de uso.

Decorridas as etapas de pesquisa, proposição de método comparativo, levantamento de alternativas, execução do modelo e subsequente análise do desempenho dos algoritmos, e, por fim, a aferição de resultados, espera-se obter um método capaz de demonstrar se é viável o aproveitamento das imagens (hoje desempregadas no contexto em epígrafe) para utilização nas atividades policiais. Tal constatação poderá gerar, também como resultado, a sensibilização da direção do órgão quanto a necessidade e a importância de investimentos na adoção de soluções de reconhecimento facial, seja por meio de desenvolvimento interno, ou de aquisições e contratações oportunizadas por certames licitatórios.

1.4 OBJETIVOS

Esta subseção apresenta o objetivo geral da pesquisa realizada, o qual sintetiza o que se pretende alcançar, bem como os objetivos específicos, os quais são as etapas necessárias ao cumprimento do objetivo principal.

1.4.1 Objetivo Geral

Propor um método para a avaliação de ferramentas de reconhecimento facial de código aberto, adequado a um conjunto de dados baseado em fotografias de identificação.

1.4.2 Objetivos Específicos

- a) Identificar, com base em revisão da literatura, as opções de ferramentas de reconhecimento facial de código aberto disponíveis para prototipação.
- b) Propor a criação, dimensionamento e características de *datasets* que possam ser consumidos em ensaios de soluções de/ reconhecimento facial.
- c) Desenvolver protótipos de reconhecimento facial com *frameworks* selecionados a partir do item “a” e os *datasets* construídos no item “b”.
- d) Identificar métricas de avaliação de acurácia que melhor se adequem ao contexto desta pesquisa.

1.5 ESTRUTURA DA DISSERTAÇÃO

Vencido o preâmbulo que introduziu a temática de estudos, o problema de pesquisa que se pretende elucidar, bem como a justificativa e os objetivos do trabalho, o presente documento foi estruturado conforme segue. Inicialmente, será apresentada a fundamentação teórica utilizada nos sistemas de reconhecimento facial modernos, em especial a explanação das tecnologias associadas às redes neurais artificiais e ao aprendizado de máquina.

Na sequência, serão descritos os procedimentos metodológicos adotados ao longo do desenvolvimento desta dissertação, destacando-se: (a) a revisão sistemática da literatura, na qual se buscou o estado da arte dos algoritmos de reconhecimento facial; (b) a elaboração e proposta de um método de avaliação - que é o propósito final do trabalho; (c) a realização de ensaios utilizando protótipos de reconhecimento facial, a partir da execução do método proposto; e (d) a apresentação dos resultados encontrados e dos aspectos (positivos e negativos) percebidos.

Por fim, o autor apresentará suas conclusões com base nos achados da pesquisa, descrevendo de forma resumida a eficácia do método no comparativo dos algoritmos testados, e sugerindo possibilidades de trabalhos futuros, os quais poderão utilizar o presente estudo como ponto de partida.

2 FUNDAMENTAÇÃO TEÓRICA

Esta seção apresenta as áreas de pesquisa de maior relevância e pertinência à temática estudada e que serão utilizadas no decorrer do documento; na sequência, são demonstrados trabalhos relacionados especificamente aos objetivos do projeto.

2.1 APRENDIZADO DE MÁQUINA (*MACHINE LEARNING*)

Alpaydın (2009) explica que o aprendizado de máquina (*machine learning*) se trata da programação de computadores para a otimização de critérios de desempenho utilizando-se de dados de exemplo ou de experiências anteriores. Um caso onde tal aprendizado é necessário é quando a aptidão humana não existe, ou quando humanos não conseguem explicar sua *expertise*. Considere o reconhecimento da fala: nós podemos desempenhar esta tarefa sem maiores dificuldades, mas somos incapazes de explicar como o fazemos. No aprendizado de máquina, uma abordagem possível é a de colecionar uma vasta quantidade de sentenças pronunciadas por diferentes pessoas, e assimilar uma forma de mapeá-las para palavras escritas.

Acrescenta Mitchell (2006) que o aprendizado de máquina é a superação natural da interseção entre a Ciência da Computação e a Estatística. Argumenta o autor que uma máquina aprende a respeito de uma tarefa particular T, métrica de desempenho P, e tipo de experiência E, se o sistema confiavelmente melhora sua performance P na tarefa T, a partir da experiência E. Dependendo de como são especificados T, P e E, tal aprendizado também pode ser denominado como mineração de dados, descobrimento autônomo, atualização de base de dados, programação por exemplos etc.

Witten et al. (2016) interpretam o aprendizado de máquina como a aquisição de descrições estruturadas a partir de exemplos. Os tipos de descrições encontradas podem ser utilizados para previsões, para explicações, e para entendimento. Aplicações de *data mining* que focam na predição geram previsões para o que acontece em novas situações usando dados que descrevem o que aconteceu no passado, comumente adivinhando a classificação de novos exemplos. Os autores apresentam ainda uma definição operacional para o aprendizado: “coisas aprendem quando mudam seu comportamento de forma que possam desempenhar melhor no futuro”. Tal definição associa o aprendizado à performance em detrimento do conhecimento.

Por sua vez, Zhou et al. (2017) discorrem que as técnicas atuais de aprendizado de máquina têm gerado enormes impactos sociais em uma vasta gama de aplicações, tais quais a

visão computacional, o processamento de linguagem natural, a neurociência, a saúde, e a Internet das Coisas. De um lado, o Big Data provê informações de riqueza não precedente para que os algoritmos extraíam padrões e construam modelos preditivos; de outro, os algoritmos tradicionais encontram desafios críticos como a escalabilidade, para que verdadeiramente possam usufruir do valor intrínseco desses dados. Os autores acrescem que o *machine learning* tradicional estabeleceu conjuntos de métricas para avaliação de performance, podendo-se citar, dentre vários outros, a acurácia e a taxa de erros, e de métricas relacionadas à escalabilidade, como a tolerância a falhas, processamento em tempo real, uso de memória etc. A apreciação, entretanto, não é uma combinação simples entre ditos dois conjuntos, mas precisa considerar o custo/benefício de combinações mais complexas, como por exemplo, precisão e taxa de retorno de verdadeiros positivos, ou acurácia e tempo de resposta.

Monard e Baranauskas (2003) complementam, a respeito da hierarquia do aprendizado de máquina:

A indução é a forma de inferência lógica que permite obter conclusões genéricas sobre um conjunto particular de exemplos. [...] O aprendizado indutivo pode ser dividido em supervisionado e não-supervisionado. No aprendizado supervisionado é fornecido ao algoritmo de aprendizado, ou indutor, um conjunto de exemplos de treinamento para os quais o rótulo da classe associada é conhecido. Já no aprendizado não-supervisionado, o indutor analisa os exemplos fornecidos e tenta determinar se alguns deles podem ser agrupados de alguma maneira, formando agrupamentos ou clusters.

Jordan e Mitchell (2015) também apontam que os avanços recentes nesta disciplina foram impulsionados por dois fatores: o desenvolvimento de novos algoritmos de aprendizado, e a corrente explosão na disponibilidade de dados *online* e de computação de baixo custo. De acordo com os autores, uma tendência que está emergindo se refere aos sistemas de recomendações personalizadas, que utilizam dados distribuídos para inferir *links* entre pessoas e itens de interesse.

Ainda no que tange às tendências de uso de aprendizado de máquina, Huang et al. (2015) listam uma série de estudos e aplicações, dentre as quais pode-se destacar, no campo da medicina e biomedicina, a predição de interações proteína-proteína, o reconhecimento de padrões de epilepsia em eletroencefalogramas, e o diagnóstico de doenças de tireoide; no campo da visão computacional, o reconhecimento facial, o reconhecimento de ações humanas, a comparação de impressões datiloscópicas, e a navegação baseada em superfície; e no campo do processamento de imagens, a geração de figuras de alta resolução com base em entradas de baixa resolução.

2.2 REDES NEURAIIS ARTIFICIAIS

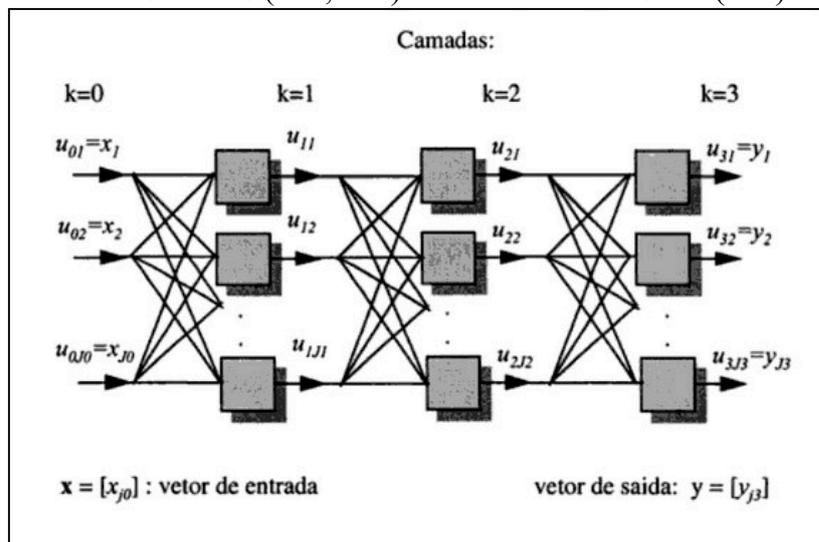
Redes neurais artificiais (RNAs) são modelos computacionais programados para realizar aprendizado de máquina e reconhecimento de padrões, inspirados no funcionamento de um cérebro. Haykin (2009) oferece a seguinte definição de rede neural:

Uma rede neural é um processador massivamente paralelo distribuído feito de unidades de processamento simples que possuem propensão natural para guardar conhecimento e torná-lo disponível para uso. Ela lembra o cérebro em dois aspectos: (1) Conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizado. (2) A energia das conexões intraneurais, conhecidas por pesos sinápticos, são usadas para guardar o conhecimento adquirido.

O procedimento utilizado para o desempenho do processo de aprendizado é chamado de algoritmo de aprendizado, cuja função é a de modificar os pesos sinápticos da rede em uma forma ordenada, no intuito de obter um objetivo projetado. Kovács (2002) traz um histórico das redes neurais artificiais:

No final da década de 1950, Rosenblatt na Universidade de Cornell, deu prosseguimento às ideias de McCulloch. Ele criou uma genuína rede de múltiplos neurônios do tipo discriminadores lineares e chamou esta rede de perceptron. Um perceptron é uma rede com uma tipologia apresentada na Figura 1, com os neurônios dispostos em várias camadas. Os neurônios que recebem diretamente as entradas da rede constituem o que se chama de camada de entrada. Os neurônios que recebem como entradas as saídas daqueles da camada de entrada constituem a segunda camada e assim sucessivamente até a camada final que é a camada de saída. As camadas internas que não são nem a de entrada e nem a de saída são geralmente referidas como camadas ocultas.

Figura 1 - Uma rede neural multicamada com uma primeira camada de entrada ($k=0$), duas camadas ocultas ($k=1, k=2$) e uma camada de saída ($k=3$).



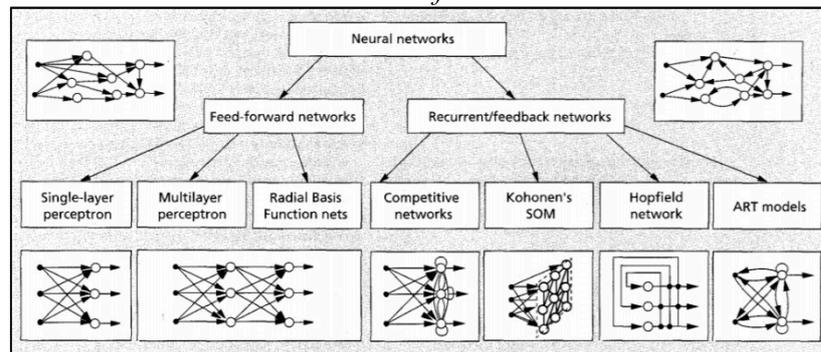
Fonte: KOVÁCS (2002).

Segundo elucidam Turaga et al. (2010), redes neurais usualmente são classificadores que operam sobre entradas contendo vetores de valores, para então produzir, como saída, previsões escalares (valores numéricos) - ou também vetoriais. Similarmente, tanto as redes neurais como as redes convolucionais (que serão explicadas na sequência) podem ser descritas por meio de um grafo. Entretanto, enquanto as arestas e vértices da primeira são valorados por escalares, nas redes convolucionais os valores são baseados em imagens.

Acrescentam os autores que uma rede neural pode ser aplicada a um problema de processamento de imagens de diversas maneiras - na mais simples delas, os *pixels* de uma figura são reordenados como um vetor e providos como entrada para uma rede. Esta abordagem se apresenta compatível com tarefas como o reconhecimento de imagens, onde o valor de *input* é uma figura, mas a saída é numérica ou vetorial.

Jain e Mao (1996) explicam que, de acordo com seu padrão de conexões, a arquitetura de uma rede neural artificial pode ser classificada de duas formas (ilustrado na Figura 2): redes *feed-forward*, nas quais não há laços (*loops*) entre o grafo, e redes recorrentes ou *feedback*, nas quais os laços ocorrem em decorrência de conexões de *feedback*. A família mais comum de redes *feed-forward* é a chamada *perceptron* multicamada, na qual os neurônios são organizados em camadas com conexões unilaterais entre si.

Figura 2 - Uma taxonomia de arquiteturas de redes neurais *feed-forward* e recorrentes/*feedback*.



Fonte: JAIN e MAO (1996).

Por sua vez, quanto ao paradigma de aprendizado, de acordo com Walczak (2019), existem duas abordagens principais. A primeira, denominada aprendizado supervisionado, é aquela na qual é utilizada a diferença entre a saída calculada e a saída conhecida para ajustar e determinar os pesos da rede; são exemplos desta categoria o *back propagation*, a Radial Basis Function (RBF), a *counterpropagation*, e as redes Fuzzy ARTMAP. Já na segunda abordagem, chamada de aprendizado não-supervisionado, a rede somente recebe estímulos de entrada, devendo se auto-organizar com o objetivo de produzir elementos de processamento escondidos que respondam diferentemente para cada conjunto de entrada, ou seja, a rede não requer informação acerca da acurácia de sua saída; são exemplos dessa categoria o Adaptive Resonance Theory (ART), o Self-Organizing Map (SOM), e as redes Hopfield.

Da Silva et al. (2017) classificam as áreas potenciais de utilização das redes neurais da seguinte forma: aproximação de funções (relacionamentos entre variáveis a partir de um conjunto de valores conhecidos), controle de processos (para utilização em requisitos de qualidade, eficiência ou segurança), reconhecimento de padrões (e classificação), agrupamento de dados (*clustering*), sistemas de predição (estimativas de valores futuros), sistemas de otimização (minimização ou maximização de funções de custos), e memória associativa (recuperação de padrões corretos mesmo quando seus elementos internos estiverem incertos ou incorretos). Conforme será apresentado a seguir, as redes neurais artificiais são um dos pilares da área de aprendizado de máquina denominado *deep learning*.

2.2.1 Deep learning

Dentre diversas interpretações possíveis acerca da definição de *deep learning*, concluem Deng et al. (2014) que dois aspectos comuns se sobressaem: (1) são modelos que consistem em múltiplas camadas ou estágios de processamento não-linear de informações; e (2) são métodos supervisionados ou não-supervisionados de representações de características (*features*) em camadas sucessivamente mais altas e abstratas. *Deep learning* se encontra nas interseções entre as áreas de pesquisa de redes neurais, inteligência artificial, modelagem gráfica, otimização, reconhecimento de padrões, e processamento de sinais. Três importantes fatores para a sua popularização na atualidade são o aumento drástico na capacidade de processamento dos *chips*, o acréscimo significativo do tamanho dos dados usados para treinamento, e os recentes avanços nas pesquisas sobre aprendizado de máquina e processamento de sinais e de informações.

Schmidhuber (2015), por sua vez, estabelece o vínculo entre uma rede neural tradicional e uma rede neural profunda (*deep*): a primeira consiste de vários processadores simples e conectados (chamados neurônios). Neurônios de entrada (*input*) são ativados por meio de sensores que percebem o ambiente, e outros neurônios são ativados por meio de conexões com pesos a partir de neurônios previamente ativados. O aprendizado se trata, doravante, de se encontrar os pesos que fazem com que a rede apresente o resultado desejado. Dependendo do problema e de como os neurônios são conectados, tal comportamento pode prever o uso de longas cadeias de estágios (ou camadas) computacionais, onde cada estágio transforma a ativação da rede. O *deep learning*, então, é a atribuição de aprendizado com acurácia através de múltiplos estágios ou camadas, estando em tal multiplicidade a diferenciação entre uma rede neural rasa (*shallow*) ou profunda (*deep*).

Patterson e Gibson (2017) oferecem a definição de que *deep learning* são redes neurais com um grande número de parâmetros e de camadas, construídas sobre uma de quatro arquiteturas fundamentais: redes pretreinadas não-supervisionadas, redes neurais convolucionais, redes neurais recorrentes, e redes neurais recursivas (admitindo-se também arquiteturas híbridas). Goodfellow, Bengio e Courville (2016) complementam que o termo moderno “deep learning” vai além da perspectiva neurocientífica utilizada na geração atual de modelos de aprendizado de máquina. Ele apelaria a um princípio mais generalizado de aprendizado em níveis múltiplos de composição, os quais podem ser aplicados em *frameworks* que não necessariamente sejam inspirados em neurônios. Os autores explicam que a pesquisa

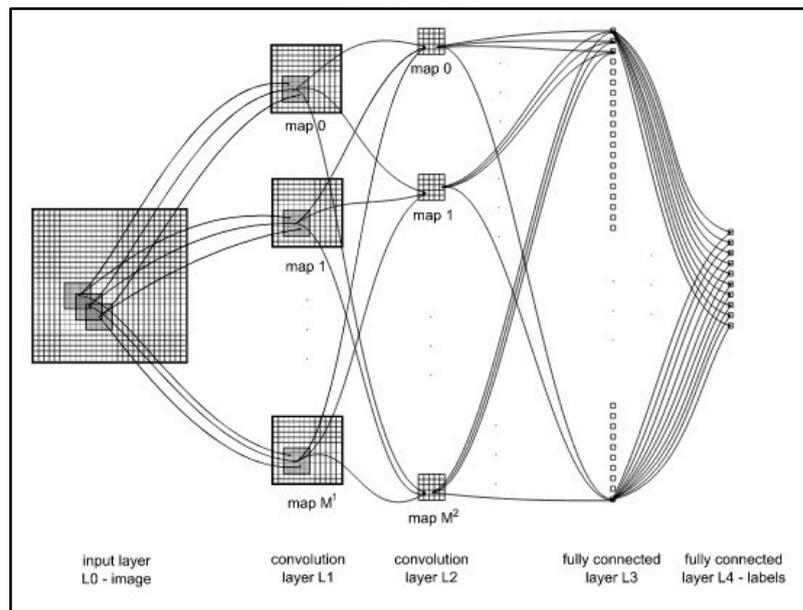
em redes neurais artificiais se iniciou nas décadas de 1940-1960 na primeira onda de teorias de aprendizado biológico e implementação de modelos iniciais (como o *perceptron*), que permitiu o treinamento de um neurônio simples; a segunda onda se iniciou no período de 1980 a 1995, com a *back propagation* para o treinamento de uma rede neural com uma ou duas camadas ocultas; por último, a terceira (e atual) onda se iniciou por volta de 2006, com o *deep learning*.

2.2.2 Redes Neurais Convolucionais

Redes neurais convolucionais (CNNs), também chamadas ConvNets, são projetadas para o processamento de dados em forma de *arrays* (sequências) múltiplos, como por exemplo uma imagem colorida composta de três *arrays* contendo os valores de seus *pixels* para cada canal de cor. Várias modalidades de dados são armazenadas na forma de *arrays* múltiplos: 1D para sinais, 2D para imagens ou áudios, 3D para vídeos ou imagens volumétricas (LECUN; BENGIO; HINTON, 2015).

Ciresan et al. (2011) descrevem redes neurais convolucionais como redes neurais hierárquicas, cujas camadas convolucionais se alternam com camadas de subamostras, variando em como tais camadas são organizadas, e em como as redes são treinadas. Como exemplo, construíram uma CNN (ilustrada na Figura 3) com base em uma camada de pré-processamento de imagens (a qual aplica filtros pré-definidos, como contrastes ou gradientes), uma camada convolucional (parametrizada pelo número e tamanho dos mapas e do núcleo, dos fatores de *skip*, e da tabela de conexão), uma camada *max-pooling* (a qual leva a uma convergência mais rápida, a uma seleção superior de características e invariantes, e uma melhor generalização), e, por fim, uma camada de classificação. Conexões do tipo *skip*, conforme descrevem Bell et al. (2016), ocorrem quando ativações de uma camada mais baixa são encaminhadas diretamente para uma camada mais alta, ignorando camadas intermediárias; Yasrab (2019) explica que as conexões *skip* aumentam o fluxo de informações dentro da rede neural, mitigam singularidades, e melhoram seu desempenho. *Max-pooling*, consoante definição dada por Ranzato et al. (2007), é uma camada que encontra o maior valor em cada mapa de características, guardando a posição do valor como o “parâmetro de transformação” para aquele mapa.

Figura 3 - Exemplo de arquitetura de uma rede neural convolucional com camadas totalmente conectadas.



Fonte: CIRESAN et al. (2011).

À medida que as ConvNets foram evoluindo, tanto em performance como acurácia, seus usos também foram se diversificando, passando de aplicações iniciais como reconhecimento de escrita e OCR (Object Character Recognition - tecnologia comumente embutida em *scanners*), para a solução de problemas mais sofisticados, como o reconhecimento facial, a detecção de objetos em imagens, o uso na medicina diagnóstica e no controle de qualidade industrial. Um *case* que ilustra o emprego dessas redes numa problemática de larga escala foi descrito por Frome et al. (2009), onde as imagens disponibilizadas no Google Street View são processadas para que sejam desfocados os rostos de pessoas e as placas veiculares, buscando assim a preservação da privacidade daqueles eventualmente capturados. Outra aplicação foi descrita por Aneja, Deshpande e Schwing (2018), na qual uma CNN foi construída para a demonstração de sua eficiência na geração automatizada de legendas descritivas para figuras, uma tarefa comumente utilizada por indexadores de imagens, assistentes virtuais, e apoio a deficientes visuais.

2.3 TRANSFER LEARNING

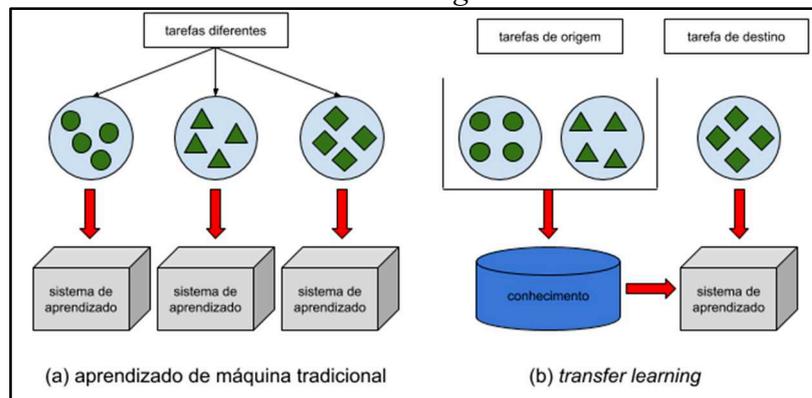
O aprendizado por transferência (*transfer learning*) se trata da melhoria do aprendizado em uma nova tarefa, por meio da transferência de conhecimento a partir de uma tarefa correlata que já foi executada. Conforme explicam Torrey e Shavlik (2010), enquanto a

maior parte dos algoritmos de *machine learning* é projetada para abordar problemas específicos, o *transfer learning* busca desenvolver métodos para transferir o conhecimento adquirido em uma ou mais tarefas de origem, e utilizá-lo para melhorar o aprendizado em uma tarefa similar de destino.

Como constatações do *transfer learning* no mundo real, Pan e Yang (2010) exemplificam que a nossa habilidade de reconhecer maçãs nos auxilia no reconhecimento de pêras; similarmente, o aprendizado em tocar um teclado eletrônico pode facilitar a prática do piano. A Figura 4 ilustra a diferença no processo tradicional de aprendizado de máquina para o *transfer learning*.

Rosenstein et al. (2005), explicam que o aprendizado para o desempenho de uma tarefa de destino - a tarefa para a qual a performance é finalmente mensurada - é influenciada pelo viés indutivo aprendido a partir de uma ou mais tarefas auxiliares. Como exemplo, citam que atletas fazem uso de *transfer learning* quando praticam habilidades fundamentais para melhorarem o treinamento em um contexto mais competitivo.

Figura 4 - Processos de aprendizado distintos entre o *machine learning* tradicional e o *transfer learning*.



Fonte: PAN e YANG (2010).

No contexto da presente pesquisa, Cao et al. (2013) estudaram a possibilidade da utilização de conceitos de *transfer learning* para o processo de detecção e verificação de faces, concluindo que a aplicação da técnica é compatível e desejável. A explicação é que bases de dados de grande escala, provenientes da Web, contêm uma variedade de informações relevantes que podem ser usadas para direcionar as previsões naqueles domínios específicos, de menor porte, e com mais nuances.

2.4 SISTEMAS DE RECONHECIMENTO FACIAL

Trigueros, Meng e Hartnett (2018) explanam que os sistemas de reconhecimento facial são usualmente compostos de quatro blocos, sintetizados na Figura 5 e descritos abaixo:

- a) Detecção: um detector encontra as posições das faces em uma imagem e retorna as respectivas coordenadas dos retângulos (caixas) que as contêm.
- b) Alinhamento: o objetivo desta etapa é redimensionar e recortar as imagens das faces de uma mesma maneira, utilizando pontos de referência localizados em regiões fixas; este processo tipicamente requer a descoberta de um conjunto de pontos e, no caso de alinhamentos em 2D simples, a aplicação de uma transformação que melhor se encaixe nessas referências.
- c) Representação: neste estágio, os *pixels* da imagem de um rosto são transformados em um vetor numérico de características compacto e discriminativo, também conhecido como *template*; idealmente, todas as imagens de um mesmo indivíduo devem ser mapeadas para vetores similares.
- d) Comparação: nesta etapa, dois *templates* são comparados para que seja produzido uma métrica (*score*) de similaridade que indique a probabilidade de que pertençam à mesma pessoa.

Figura 5 - Blocos de construção de um sistema de reconhecimento facial.



Fonte: TRIGUEROS e MENG (2018).

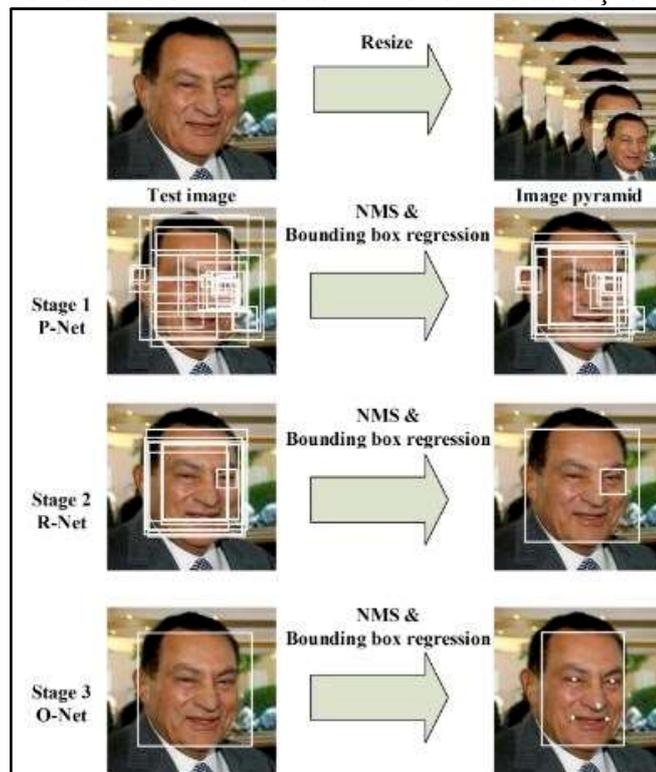
Dentre as técnicas de detecção e alinhamento de faces mais utilizadas pelos sistemas modernos, destacam-se a *dlib*, introduzida por King (2009) e utilizada pelo *OpenFace* de Amos, Ludwiczuk e Satyanarayanan (2016) com base em modelos pré-treinados, e o *Multitask Convolutional Neural Network (MTCNN)*, apresentada por Zhang et al. (2016) e utilizado pelo *FaceNet* de Sandberg (2016).

A dinâmica de funcionamento do *framework* em cascata MTCNN, ilustrada na Figura 6, inclui redes convolucionais profundas multitarefas em três estágios. Primeiramente, janelas candidatas são produzidas por uma rede rápida de propostas (P-Net); na próxima etapa, as

candidatas são apuradas através de uma rede de refinamento (RNet); no terceiro estágio, a rede de saída (O-Net) produz o retângulo com a localização da face, bem como as posições de referência (*landmarks*).

Em consideração às soluções identificadas na revisão de literatura, Richard Webster et al. (2018) apresentam um confronto entre o OpenFace de Amos, Ludwiczuk e Satyanarayanan (2016) e o FaceNet de Sandberg (2016): enquanto ambos reportam implementar o algoritmo FaceNet do Google proposto por Schroff, Kalenichenko e Philbin (2015), o segundo demonstrou propriedades relacionadas a invariantes mais fracas comparadas ao primeiro; da mesma forma, o FaceNet teria utilizado em seu treinamento um subconjunto do *dataset* MS-Celeb-1M, onde imagens mais difíceis dotadas de oclusão parcial ou silhuetas foram removidas, perdendo então uma oportunidade de aprendizado de invariantes sob tais condições. Acrescentam ainda os autores do comparativo que, enquanto o OpenFace usa a exata arquitetura descrita por Schroff et al., o FaceNet de Sandberg opta pela Inception ResNet v1.

Figura 6 - Dinâmica de funcionamento do framework de detecção de faces MTCNN.



Fonte: ZHANG et al. (2016).

Argumenta-se que o componente de representação de faces seja o mais importante de um sistema de reconhecimento facial, e aquele que mais tem recebido foco, uma vez que os

dois primeiros componentes já atingiram níveis maduros de confiabilidade, e o último comumente é reduzido à matemática simples, como por exemplo utilizando-se de distâncias euclidianas.

Dentre os avanços nesta etapa, uma inovação de impacto e que é utilizada por várias redes neurais foi o modelo de Triplet Loss introduzido pelo FaceNet de Schroff, Kalenichenko e Philbin (2015). O princípio deste modelo é minimizar a distância entre uma imagem âncora e uma imagem positiva, ambas dos quais pertencem à mesma identidade, e maximizar a distância entre a âncora e uma imagem negativa (de uma identidade diferente). Tal esquema de funcionamento é ilustrado na Figura 7.



Hermans, Beyer e Leibe (2017) explicam que esta função de perda (*loss*) garante que, dado um ponto âncora x_a , a projeção de um ponto x_p positivo pertencente à mesma classe (pessoa) y_a está mais perto da projeção da âncora do que da projeção de um ponto negativo pertencente a outra classe y_n , por ao menos uma margem m . Se esta perda for suficientemente otimizada para todo o conjunto de dados, eventualmente todos os pares possíveis (x_a, x_p) estarão aproximados. A vantagem desta fórmula é que, enquanto eventualmente todos os pontos de uma mesma classe formarão um *cluster* (agrupamento) único, eles não necessariamente precisam se fundir em um único ponto; eles apenas precisam estar mais pertos uns dos outros do que de quaisquer outros pontos de classes diferentes.

Conforme será explicado e justificado na revisão da literatura, serão três os *frameworks* de reconhecimento facial utilizados nos ensaios da presente pesquisa, todos os quais alicerçados nos fundamentos de redes neurais apresentados. As seguintes subseções explicam, de forma resumida, o funcionamento de cada uma dessas soluções.

2.4.1 VGG-Face

VGG-Face é uma solução baseada em redes neurais convolucionais descrita por Parkhi, Vedaldi e Zisserman (2015) e desenvolvida pelo Visual Geometry Group da Universidade de Oxford. As redes utilizadas no treinamento de faces foram descritas pelos autores como “muito profundas”, no sentido de que comprimem uma longa sequência de camadas convolucionais, conforme ilustrado na Figura 8.

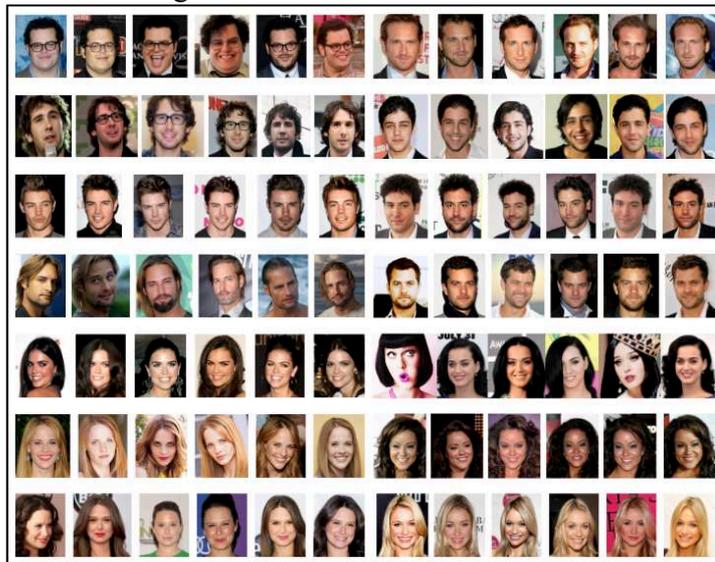
Figura 8 - Ilustração das camadas da rede neural profunda utilizada pelo VGG-Face.



Fonte: PARKHI, VEDALDI E ZISSERMAN (2015).

A construção do *dataset* utilizado no treinamento das redes teve por base as fotografias de celebridades do Internet Movie Data Base (IMDB), conforme amostrado na Figura 9. Esse conjunto se iniciou com aproximadamente 1 milhão de fotos de 5.000 indivíduos distintos, tendo sido posteriormente refinado por processos tanto manuais como automáticos (remoção de fotografias similares ou duplicadas, limpeza de rótulos errôneos, e acréscimo de fotos de fontes externas - Google e Bing - para se obter imagens adicionais de cada sujeito).

Figura 9 - Amostras das fotografias utilizadas no dataset de treinamento do VGG-Face.



Fonte: PARKHI, VEDALDI E ZISSERMAN (2015).

O processo de construção desse conjunto de dados foi também uma contribuição adicional do trabalho, uma vez que *datasets* de larga escala e com pouco ruído são importantes e necessários no treinamento das redes neurais atuais. Os autores da ferramenta descrevem na sequência o treinamento de uma rede classificadora de rostos, a qual produz um vetor de *scores* que pode ser utilizado para verificação de identidades por meio de distâncias euclidianas, mas acrescentam que esses *scores* são significativamente melhorados usando-se de um esquema de *triplet loss* (descrito na subseção anterior).

Findada a etapa de aprendizado, a solução foi então testada no *dataset* Labeled Faces in the Wild (LFW), quando atingiu 98,95% de acurácia, e no *dataset* YouTube Faces, atingindo 97,3% de acerto. Ressaltam, ao término do *paper*, que o procedimento foi desenvolvido para o reconhecimento facial, entretanto, a mesma lógica poderia ser aplicada para outras classes de objetos ou de tarefas.

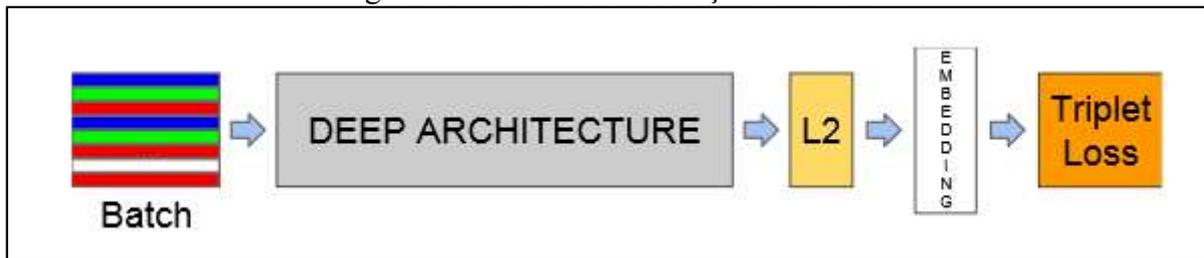
2.4.2 FaceNet

O FaceNet, proposto por Schroff, Kalenichenko e Philbin (2015) do Google Inc, é um sistema que aprende a mapear rostos para um espaço euclidiano compacto, no qual as distâncias correspondem diretamente a uma medida de similaridade das faces. Uma vez que esse espaço é produzido, tarefas como o reconhecimento facial, a verificação de identidade, e o agrupamento (*clustering*) podem ser facilmente implementadas empregando-se técnicas simples com os mapeamentos FaceNet usados como vetores de características (*features*).

O método adotado utiliza uma rede neural convolucional profunda, treinada para otimizar diretamente os próprios mapeamentos – ao invés de utilizar uma camada como gargalo intermediário, como em outras abordagens anteriores de *deep learning* – e produzir, como saída, representações usando uma função de *triplet loss*, essa última já descrita. A Figura 10 ilustra a estrutura da proposta, que consiste de uma camada de entrada de lote (*batch*) e uma CNN profunda, seguida de uma camada de normalização L_2 , a qual resulta na representação (*embedding*), e que, durante o treinamento, é seguida da função de *triplet loss*.

O benefício dessa abordagem está em sua eficiência, já que conseguem obter resultados considerados estado-da-arte com somente 128 *bytes* por face representada. A título de curiosidade, informam os autores terem realizado a etapa de aprendizado de seu modelo em um *cluster* de CPUs por 1.000 a 2.000 horas.

Figura 10 - Estrutura da solução FaceNet.



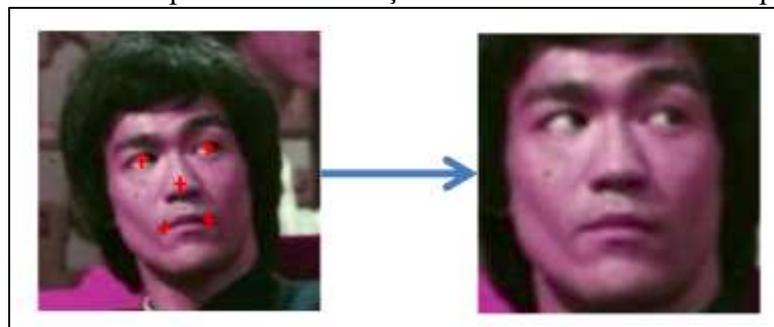
Fonte: SCHROFF, KALENICHENKO e PHILBIN (2015)

Findado o treinamento do modelo, sua capacidade de predição foi então testada no *dataset* Labeled Faces in the Wild (LFW), tendo atingido 98,87% de acurácia quando utilizado um recorte centralizado de faces, e um *score* recorde de 99,63% quando utilizado um alinhamento de rostos adicional. Adicionalmente, a solução foi também testada no *dataset* YouTube Faces DB, dessa vez com uma acurácia de 95,12%.

2.4.3 VIPLFaceNet

O VIPLFaceNet é um *Software Development Kit* (SDK) desenvolvido na linguagem C++ e registrado sob a licença de código aberto *Berkeley Software Distribution* (BSD), gratuito tanto para uso acadêmico como comercial. A solução foi apresentada por Liu et al. (2017), da University of Chinese Academy of Sciences, e se trata de uma rede neural convolucional profunda de dez camadas, sendo 7 camadas convolucionais e 3 camadas totalmente conectadas. Os autores adaptaram ainda uma camada de normalização rápida, a qual objetiva reduzir a variância da entrada a zero (conforme exemplificado na Figura 11), dessa forma otimizando a convergência (velocidade em que a rede atinge seus resultados) e melhorando a generalização.

Figura 11 - Exemplo de normalização de um rosto utilizando 5 pontos.



Fonte: LIU ET AL. (2017)

Em seus experimentos, as imagens contendo faces são pré-processadas em três etapas, sendo a primeira de detecção dos rostos, a segunda de localização de coordenadas faciais (*landmarks*), e a terceira a de normalização, conforme ilustrada acima. O *dataset* utilizado para o treinamento da rede foi o CASIA-Web, contendo 479.777 imagens de 10.575 indivíduos. Posteriormente à etapa de aprendizado, a rede foi avaliada no *dataset* Labeled Faces in the Wild (LFW), tendo atingido 98,6% de acurácia.

Os conceitos apresentados nessa seção, em especial os fundamentos de aprendizado de máquina e de redes neurais convolucionais, compõem os pilares de construção dos sistemas de reconhecimento facial modernos. Na próxima seção, veremos como serão aplicadas à pesquisa, e de que forma essas áreas foram encontradas na revisão bibliográfica.

3 PROCEDIMENTOS METODOLÓGICOS

Nesta seção serão descritos os atributos da proposição de pesquisa e as etapas seguidas na Revisão Sistemática de Literatura, cujos achados serviram como embasamento do presente projeto.

3.1 CARACTERIZAÇÃO DA PESQUISA

Sob o prisma da natureza da pesquisa, a proposta tem por objetivo gerar conhecimentos para uma aplicação prática e direcionados à solução de um problema específico, destarte podendo ser classificada como Pesquisa Aplicada. Por sua vez, em relação à abordagem adotada, estando a problemática enraizada em solo computacional, e passíveis os resultados esperados de serem classificados e traduzidos em números (métricas) e critérios estatísticos (portanto exatos), pode assim a pesquisa ser rotulada como Quantitativa.

Já sob o ponto de vista dos seus objetivos, observado que se pretende obter familiaridade com o problema por meio de levantamentos bibliográficos e estudos de caso, e em consequência construir hipóteses, pode-se categorizar a pesquisa como Exploratória.

Por fim, sob a óptica dos procedimentos técnicos, foram adotadas as classificações Bibliográfica, Documental e Experimental, por consequência das etapas elencadas nos objetivos específicos deste trabalho, e em especial considerando a adoção tanto de pesquisas bibliográficas em material publicado, como a determinação de um objeto de estudo e das variáveis que o influenciam.

Os atributos utilizados para a caracterização da pesquisa proposta foram sumarizados no Quadro 1.

Quadro 1 - Sumarização da caracterização da pesquisa.

Natureza do trabalho	Pesquisa Aplicada
Abordagem do problema	Quantitativa
Natureza do objetivo	Pesquisa Exploratória
Procedimentos técnicos	Pesquisa Bibliográfica, Documental e Experimental

Fonte: elaborado pelo autor.

3.2 REVISÃO SISTEMÁTICA DA LITERATURA

Para o levantamento bibliográfico, foi adotada a metodologia de Revisão Sistematizada da Literatura (RSL) conforme proposta por Galvão e Pereira (2014), a qual sugere a elaboração de uma pergunta de pesquisa, a realização de buscas na literatura, a seleção dos textos, a extração dos dados, a avaliação da qualidade metodológica, a síntese das informações, a análise da qualidade das evidências e, por fim, a redação e publicação dos resultados.

Em atenção a este roteiro, definiu-se que o objetivo da realização da RSL é a estruturação de um arcabouço teórico sobre publicações que tratam da temática de ferramentas *open source* de reconhecimento facial. Para tanto, foi definida a seguinte questão a ser satisfeita: Quais tecnologias (algoritmos ou *frameworks* computacionais) de código aberto apresentam os melhores resultados, permitindo a implementação de protótipo de reconhecimento facial baseado em imagens singulares de sujeitos?

Para responder ao questionamento formulado, definiu-se que as buscas pelas publicações seriam realizadas nas seguintes bases de dados: ACM Digital Library, Springer Link, Science Direct, Scopus e IEEE Xplore Digital Library, escolhidas pela sua reputação internacional, por agruparem um significativo número de periódicos, e, principalmente, pela aderência à área de interesse e subsequente direcionamento ao viés tecnológico. Na eventualidade de alguma publicação não pertencente às bases acima ser citada de forma recorrente e relevante durante as leituras, tal trabalho também será inserido na revisão, devidamente referenciado.

Verificou-se, em pesquisas preliminares, que a utilização de palavras-chaves restritivas para o contexto a ser pesquisado (tais quais “*single sample*” ou “*single image*”) delimitaram de forma demasiada os resultados. Assim sendo, optou-se por uma busca mais ampla, usando somente os termos “código aberto” e “reconhecimento facial” nos idiomas português, espanhol e inglês, postergando a exclusão dos textos que não abordam a problemática da escassez de imagens como entrada para os algoritmos para a etapa seguinte (filtragem e exclusão). Adicionalmente, considerando a velocidade do ciclo evolutivo das ferramentas computacionais, optou-se pela avaliação dos textos publicados apenas nos cinco anos anteriores à realização da pesquisa, executada ao início de 2019 (portanto 2014 a 2018).

O Quadro 2 apresenta os critérios de inclusão de publicações na pesquisa, ou seja, para cada uma das bases de dados, as coleções ou disciplinas selecionadas, os campos e as palavras-chave utilizadas na busca, os filtros aplicados, e os respectivos quantitativos encontrados.

Quadro 2 - Critérios de inclusão de publicações na pesquisa: bases, disciplinas, campos e palavras-chave escolhidas.

Base	Coleção	Campo	String	Filtros	Qtd
<i>ACM Digital Library</i>	<i>The ACM Guide to Computing Literature</i>	<i>Any field matches all</i>	(“reconhecimento facial” AND “código aberto”)	Ano de publicação entre 2014 e 2018	16
<i>SpringerLink</i>	<i>Discipline “Computer Science”</i>	<i>Find resources with all of the words</i>	OR		105
<i>IEEE Xplore Digital Library</i>	<i>n/a</i>	<i>Metadata only</i>	(“reconocimiento facial” AND “código abierto”)		95
<i>ScienceDirect</i>	<i>n/a</i>	<i>Title, abstract, keywords</i>	OR		3
<i>Scopus</i>	<i>n/a</i>	<i>Article title, Abstract, Keywords</i>	(“face recognition” AND “open source”)		103
Total					322

Fonte: elaborado pelo autor.

Na sequência, em virtude de a possibilidade de alguns *hits* não serem aplicáveis ao cenário de pesquisa, foram definidos critérios de exclusão. Realizou-se, após encontradas 322 publicações passíveis de inclusão, a leitura individual de cada trabalho; nesta tarefa, passou-se a desconsiderar (excluir) aqueles estudos cujo contexto é diverso da temática de interesse, e também aqueles estudos que não abordaram o uso ou apresentaram resultados de tecnologias de código aberto destinadas ao reconhecimento facial. Tais critérios foram dispostos no Quadro 3.

Quadro 3 - Critérios utilizados para a exclusão dos artigos da revisão.

Critério	Descrição
1	Estudo aborda contexto diverso da temática de interesse
2	Estudo não introduz ou não objetiva apresentar resultados ou comparativo de algoritmo(s) ou <i>framework</i> (s) de código aberto para reconhecimento facial

Fonte: elaborado pelo autor.

Aplicados os critérios de inclusão e exclusão descritos, e filtrados os resultados duplicados, foram identificados 15 (quinze) trabalhos aderentes à questão de pesquisa, os quais

serão descritos nesta seção. O Quadro 4 apresenta a relação dos documentos selecionados, enquanto os documentos excluídos foram discriminados no Apêndice D.

Quadro 4 - Trabalhos analisados depois de aplicados os critérios de inclusão e exclusão.

Autores	Título	Publicação	Ano
LIU, Xin et al.	<i>VIPLFaceNet: An Open Source Deep Face Recognition SDK</i>	<i>Frontiers of Computer Science: Selected Publications from Chinese Universities</i>	2017
VEDALDI, Andrea; LUX, Mathias; BERTINI, Marco	<i>MatConvNet: CNNs Are Also for MATLAB Users</i>	<i>ACM SIGMultimedia Records</i>	2018
HMANI, Mohamed Amine; PETROVSKADELACRÉT AZ, Dijana.	<i>State-of-the-art face recognition performance using publicly available software and datasets</i>	<i>2018 4th International Conference on Advanced Technologies for Signal and Image Processing (ATSIP)</i>	2018
BHOSITHI, Wisarut et al	<i>A Review Paper Between Open Source and Commercial SDK and Performance Comparisons of Face Matchers</i>	<i>2018 International Conference on Engineering, Applied Sciences, and Technology (ICEAST)</i>	2018
SURYAPRASAD, J. et al.	<i>Parallel implementation and performance evaluation of facial recognition algorithms using open source technologies</i>	<i>2016 International Conference on Electrical, Electronics, and Optimization Techniques (ICEEOT)</i>	2016
BUHUS, Elena Roxana; GRAMA, Lacrimioara; SERBU, Catalina	<i>A facial recognition application based on incremental supervised learning</i>	<i>2017 13th IEEE International Conference on Intelligent Computer Communication and Processing (ICCP)</i>	2017
HU, Guosheng et al.	<i>When Face Recognition Meets with Deep Learning: An Evaluation of Convolutional Neural Networks for Face Recognition</i>	<i>Proceedings of the IEEE international conference on computer vision workshops</i>	2015
HU, Jiawei; PENG, Liangrui; ZHENG, Li	<i>XFace: a face recognition system for android mobile phones</i>	<i>Cyber-Physical Systems, Networks, and Applications (CPSNA), 2015 IEEE 3rd International Conference on</i>	2015
DESHPANDE, Aditya et al	<i>Towards Designing an Adaptive Framework for Facial Image Quality Estimation at Edge</i>	<i>2018 3rd International Conference for Convergence in Technology (I2CT)</i>	2018
DANISMAN, Y. et al	<i>A comparison of eigenvalue methods for principal component analysis</i>	<i>Appl. Comput. Math, v. 13, n. 3, p. 316-331</i>	2014
BORMANN, Richard et al	<i>Person recognition for service robotics applications</i>	<i>Humanoid Robots (Humanoids), 2013 13th IEEE-RAS International Conference on</i>	2015
GÜNTHER, Manuel; EL SHAFEY, Laurent; MARCEL, Sébastien	<i>Face recognition in challenging environments: An experimental and reproducible research survey</i>	<i>Face recognition across the imaging spectrum</i>	2016

LU, Tongwei; WU, Menglu; LU, Tao	<i>Face recognition via Gabor and convolutional neural network</i>	<i>Ninth International Conference on Graphic and Image Processing (ICGIP 2017)</i>	2017
AMOS, Brandon et al.	<i>Openface: A general-purpose face recognition library with mobile applications</i>	<i>CMU School of Computer Science</i>	2016
PARKHI, Omkar M. et al.	<i>Deep face recognition</i>	<i>British Machine Vision Conference</i>	2015

Fonte: elaborado pelo autor.

Elencados os textos resultantes do processo de pesquisa e seleção, a seguir é apresentada uma breve síntese de cada estudo.

Liu et al. (2017) introduzem um *Software Development Kit* (SDK) de código aberto na linguagem C++, sob a licença *Berkeley Software Distribution* (BSD), denominado *VIPLFaceNet*. A solução para reconhecimento facial foi construída com base em uma rede neural convolucional profunda de dez camadas, sendo três convolucionais e sete totalmente conectadas. O modelo foi apresentado com resultados de alta acurácia média (98,6%) e pequeno custo computacional, utilizando para o *benchmark* o *dataset* público LFW.

Vedaldi, Lux e Bertini (2018) apresentaram uma rede neural convolucional implementada em *MATLAB*, a qual batizaram *MatConvNet*. Como pontos positivos desta solução, apontam a simplicidade de uso, e a eficiência gerada em virtude do embasamento na biblioteca CuDNN e da possibilidade de processamento em GPUs. A ferramenta oferece redes neurais pré-treinadas para classificação de imagens, reconhecimento facial, detecção de textos e de objetos.

Hmani e Petrovska-Delacrétaz (2018) treinaram um modelo de rede neural convolucional profunda no *software* de código aberto *OpenFace*, alimentando-o com os *datasets* públicos FRGC, MS-celeb-1M, MOBIO e LFW. O objetivo do estudo era verificar a reprodutibilidade de resultados previamente publicados na literatura, comparando a acurácia encontrada com aquela de soluções proprietárias tais quais o *DeepFace*, pertencente ao Facebook, e o *Facenet*, desenvolvido pelo Google. A conclusão foi de que os experimentos baseados em soluções totalmente abertas puderam ser reproduzidos de acordo com as estatísticas publicadas; em contrapartida, quando houve uso de *datasets* privados, como o do Google, a equiparação de resultados não foi possível.

Bhosithi et al. (2018) descrevem um experimento onde foi realizado um comparativo de precisão e de desempenho entre uma solução de reconhecimento facial comercial, *Verilook*

5.6, e uma gratuita de código aberto, *OpenBR 0.5*, em um cenário de controle de acesso dotado de variações de iluminação e de pose, com fotos capturadas dentro do próprio escritório. Os resultados apresentados denotam índices de acerto superiores para o pacote proprietário, todavia, o experimento restou restritivo em virtude da limitação do tamanho do *dataset*.

Suryaprasad et al. (2016) realizaram um comparativo de performance entre quatro algoritmos populares, a saber, *Principal Component Analysis* (PCA), *Linear Discriminant Analysis* (LDA), *Independent Component Analysis* (ICA) e *FisherFaces*, implementados na linguagem C++ utilizando código aberto baseado nas bibliotecas *OpenCV* e *OpenMP*. O foco principal do estudo foi a avaliação do comportamento dos algoritmos sob a óptica do processamento paralelo, dando, portanto, maior ênfase ao tempo de execução em detrimento à precisão. Para um aprimoramento futuro do presente trabalho, cujo prisma é o da acurácia, a abordagem de Suryaprasad et al. poderia servir como referência na metodologia de complemento de informações relacionadas a desempenho.

Buhus,, Grama e Serbu (2017) descrevem uma aplicação construída sobre os algoritmos *Local Binary Pattern* e *Discrete Cosine Transform* para a extração das *features*, com um classificador baseado em *Simplified Fuzzy Adaptive Resonance Theory Map*, que por sua vez é uma rede neural cuja estrutura se assemelha à das redes *feed-forward*. Para experimentação, foram usadas as bases de dados de faces AT&T, construída pelo *Computer Laboratory* da *Cambridge University*, e *Extended Yale B*, construído pela *University of California San Diego*. Os resultados reportados foram considerados promissores pelos autores, mas com a limitação de que as imagens de entrada devem apresentar pouca variação em termos de expressão facial.

Hu et al. (2015) propõem três arquiteturas distintas de redes neurais convolucionais treinadas utilizando o *dataset* LFW. O trabalho objetiva elucidar os efeitos das escolhas de implementação das redes sobre a acurácia dos resultados finais, citando como exemplos a dimensionalidade das características (*features*) utilizadas, a fusão de redes múltiplas, o número de filtros e de camadas, uso de técnicas de *data augmentation*, de tipologia dos *pixels* - se coloridos ou em escalas de cinza, e de aprendizado métrico, que por sua vez se trata da tarefa de aprender uma função de distância entre objetos. O termo *data augmentation*, conforme definição oferecida por Van Dik e Meng (2001), se refere a métodos para a construção de otimização iterativa ou algoritmos de exemplificação, por meio da introdução de dados não observados ou variáveis latentes. Para fins de reprodutibilidade, os modelos e códigos-fontes foram também publicados. Adicionalmente, apresentam comparativos de redes neurais

publicadas tais quais a *DeepFace*, *DeepID*, e *WebFace*, além da *Facenet*. Concluem os autores que a fusão de redes neurais é um fator de aumento de performance, uma vez que redes diferentes capturam a informação de diferentes regiões em escalas distintas para formar uma representação robusta.

Hu, Peng e Zheng (2015) desenvolveram um sistema de reconhecimento facial de código aberto chamado *XFace*, direcionado para a plataforma de dispositivos móveis Android. A proposta, construída sobre o SDK *OpenCV*, inclui detecção de rosto, de olhos, pré-processamento de regiões de interesse, extração de *features* por *Local Binary Pattern* (LBA), redução de dimensionalidade de *features* baseada em *Principal Component Analysis* (PCA) e *Linear Discriminant Analysis* (LDA), e, por fim, um classificador de distância mínima. A redução de dimensionalidade é um processo de redução do número de variáveis aleatórias que são consideradas, por meio da obtenção de um conjunto de variáveis principais, visando otimização de recursos. O foco principal do estudo foi a viabilização de uma solução compatível com o poder processual reduzido dos *smartphones* (em comparação a computadores PC).

Deshpande et al. (2018) propuseram um *framework* para avaliação de qualidade de uma imagem de rosto, com o objetivo de melhorar a performance de ferramentas de reconhecimento facial de tempo real. A premissa é de que imagens que tendem a não ser corretamente rotuladas possam ser descartadas antes de serem enviadas ao algoritmo de reconhecimento, evitando-se o desperdício de recursos. Para tanto, construíram, sobre o *OpenFace* e usando o *dataset Chokepoint*, um classificador binário baseado em *deep learning*, estudando a influência de variáveis (tais quais medida de foco, pose, expressão, brilho e oclusão) na acurácia dos resultados. Os achados permitiram concluir que a qualidade da imagem é essencial a um bom desempenho de algoritmos de reconhecimento, podendo-se acoplar o *framework* construído a circuitos de CFTV (por exemplo) para otimização de sistemas.

Danisman et al. (2014) compararam quatro métodos *eigenvector* destinados ao reconhecimento facial com *Principal Component Analysis* (PCA). Os autovetores, ou *eigenvectors*, em álgebra linear, são números que resumem as propriedades essenciais de uma matriz. Os métodos comparados foram a iteração cíclica de *Jacobi's*, deflação de *Wiedlandt's*, deflação de *Hotelling's*, e *eigenvalue* do *MATLAB*. Adicionalmente, estudaram os efeitos da manipulação das imagens de faces (através de aplicação de filtros) na melhoria da acurácia dos resultados, bem como mensuraram os desempenhos computacionais relativos dos métodos. Os dados utilizados nos experimentos foram o *dataset* SDS (da University of California San Diego)

e o *dataset* ORL (da University of Cambridge). Os autores concluem que o número dominante de *eigenfaces* escolhido, bem como o uso de filtros, afeta a performance geral dos algoritmos.

Bormann et al. (2013) introduzem uma solução de reconhecimento facial de código aberto direcionada a aplicações no campo da robótica (pacote ROS - *Robot Operating System*). O trabalho engloba, dentre vários módulos, a interface com um sensor de imagens, um detector de cabeças e um de faces baseado em *Viola-Jones*, um módulo de identificação baseado em *Fisherfaces*, e um detector de movimento (*tracker*) para *streams* RGB-D. *Fisherfaces* é um algoritmo de reconhecimento facial insensível a grandes variações de iluminação e expressão facial, derivado do *Fisher's Linear Discriminant*. O sistema foi avaliado utilizando-se dos *datasets* *Extended Yale Face B*, *AT&T*, e *RGB-D Kinect*. Concluem os autores que o *framework* construído apresentou resultados convincentes em cenários de mundo real (com variações de iluminação), atingindo taxas de reconhecimento da ordem de 90%, e que os requisitos computacionais são baixos o suficiente para que seja aplicado em robôs de serviço móveis.

Günther, Shafey e Marcel (2016) abordam a problemática do reconhecimento facial nas plataformas móveis, para as quais alegam um aumento na degradação das imagens durante a aquisição e transmissão dos dados. Em seu estudo, realizam um comparativo de cinco tecnologias, sendo uma solução comercial (anônima) e quatro algoritmos de código aberto: *Linear Discriminant Analysis on Color Channels*, *Gabor Grid Graphs*, *Local Gabor Binary Pattern Histogram Sequences*, e *Intersession Variability Modeling*. As imagens utilizadas são oriundas dos *datasets* *CMU Multi-PIE*, *AR* (criada no *Computer Vision Center* da *Ohio State University*), *XM2VRS*, *BANCA*, *LFW*, *MOBIO*, e *YouTube Faces*. Em um rápido sumário dos experimentos realizados, os autores concluem que não há um único algoritmo que funcione melhor para todos os casos e todas as aplicações (embora existam favoritos), e que a solução comercial demonstrou resultados superiores na maior parte dos comparativos, em especial nas poses não frontais.

Lu, Wu e Lu (2018) demonstram os resultados de uma rede neural convolucional que consome, como entrada, *features* que são extraídas de imagens por meio de *wavelets* de Gabor, as quais são um conjunto de funções construídas para embasar transformadas de *Fourier* em aplicações de teoria da informação. Os *datasets* utilizados foram o *AR*, *Yale B* e um subconjunto aleatório da *CASIA*. Para detecção e alinhamento de faces, utilizaram a *MTCNN*. Concluem os autores que as taxas de acurácia podem ser melhoradas com um aumento no mapa de características (*features*) de entrada, com a desvantagem de que um número maior de parâmetros resulta em maior complexidade no treinamento da rede neural.

Amos, Ludwiczuk e Satyanarayanan (2016) apresentam um *framework* compartilhado pela licença Apache 2.0 que encurta a distância entre as ferramentas comerciais proprietárias de reconhecimento facial e aquelas de código aberto, atingindo acurácia quase-humana no *dataset* LFW. O pacote é baseado em redes neurais *feedforward*, tomando para si princípios e técnicas oriundas do *DeepFace* (do Facebook) e também do *Facenet* (do Google). A implementação tem seu foco primário em cenários *mobile*, objetivando alta acurácia com tempos de treinamento e predição curtos. A solução apresentada, embora treinada em *datasets* uma ou duas ordens de magnitude menores do que os maiores conjuntos privados publicados, atingiu resultado competitivo.

Parkhi, Vedaldi e Zisserman (2015) publicaram um *paper* com dois objetivos principais: propor um processo para criar um *dataset* de rostos razoavelmente grande, mas que requeira um esforço limitado de intervenções humanas para anotações, e investigar diversas redes neurais convolucionais para identificação e verificação de faces, incluindo-se a exploração de alinhamento de rostos e aprendizado métrico, usando o novo *dataset* como treinamento. O código-fonte e modelos foram disponibilizados sob a licença *Creative Commons Attribution License*, tendo sido a solução denominada VGG-Face. Dentre as contribuições, afirmam ter projetado um procedimento capaz de montar um conjunto de dados de larga escala com pouco ruído de rótulos, enquanto minimizam a necessidade de anotações manuais; adicionalmente, afirmam que qualquer CNN profunda sem enfeites, mas com o devido treinamento, pode alcançar resultados comparáveis ao estado da arte.

Após a leitura e análise dos estudos selecionados, foi possível o estabelecimento e a constatação de diversas características comuns entre eles. Essas características foram sumarizadas no Quadro 5, a saber:

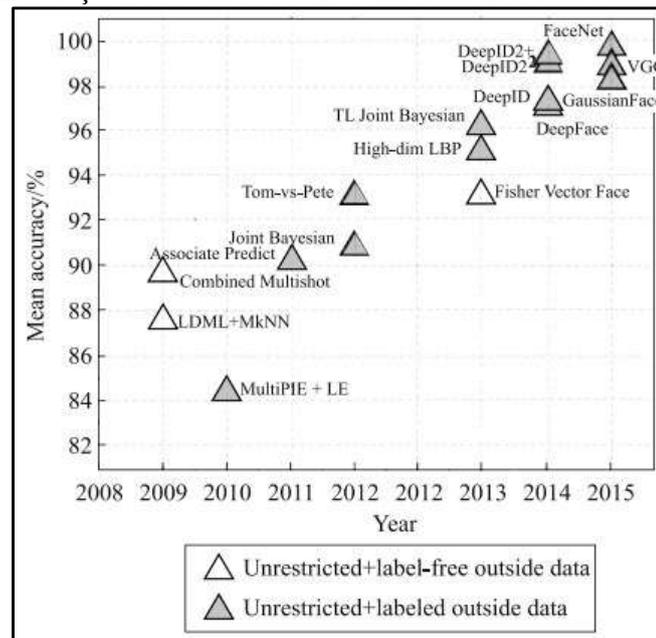
- C1: apresenta *benchmark* em *dataset* conhecido
- C2: disponibiliza ferramenta (*framework* ou biblioteca) de código aberto
- C3: utiliza redes neurais na construção do(s) algoritmo(s)

Quadro 5 - Características comuns aos trabalhos analisados.

	Trabalho	C1	C2	C3
1	Liu et al. (2017)	x	x	x
2	Vedaldi, Lux e Bertini (2018)		x	x
3	Hmani e Petrovska-Delacrétaz (2018)	x		x
4	Bhosithi et al. (2018)			
5	Suryaprasad et al. (2016)	x		
6	Buhus, Grama e Serbu (2017)	x		x
7	Hu et al. (2015)	x	x	x
8	Hu, Peng e Zheng (2015)		x	
9	Deshpande et al. (2018)	x		x
10	Danisman et al. (2014)	x		
11	Bormann et al. (2013)	x	x	
12	Günther, Shafey e Marcel (2016)	x	x	
13	Lu, Wu e Lu (2018)	x		x
14	Amos, Ludwiczuk e Satyanarayanan (2016)	x	x	x
15	Parkhi, Vedaldi e Zisserman (2015)	x	x	x

Fonte: elaborado pelo autor.

Conforme as características comuns aos trabalhos analisados, percebe-se tendência de popularização de uso de soluções baseadas em redes neurais convolucionais profundas, cujo processo evolutivo vem apresentando resultados superiores (LIU et al., 2017) aos algoritmos tradicionais (PCA, LDA, Fisherfaces etc). A Figura 12 ilustra a evolução das técnicas de reconhecimento facial sobre o *dataset* LFW, consoante explanação de Liu et al. (2017).

Figura 12 - Evolução de técnicas de reconhecimento facial no *dataset* LFW.

Fonte: XIN LIU et al. (2017)

Em apreciação à questão de pesquisa formulada, sob os critérios de busca utilizados, uma observação adicional pode ainda ser apontada: a de que nenhum trabalho recente foi identificado no qual o *dataset* de entrada (aprendizado) é composto de imagens singulares (únicas) de indivíduos, mas sempre de fotografias múltiplas, obtidas em condições diversas de luminosidade e posicionamento. Uma explicação plausível é a de que os experimentos visam o objetivo do aprendizado de máquina sobre a representação de um indivíduo a partir de diversas poses e situações, ao contrário do contexto policial onde a variabilidade deste *input* é mais escassa. Resta, portanto, a oportunidade de um estudo original: a elaboração de uma avaliação comparativa de soluções de reconhecimento facial *open source* que utilizem fotos de identificação simples em detrimento de *datasets* múltiplos, cenário particular na literatura recente.

Sob uma óptica similar, Bansal et al. (2017) analisaram o impacto dos perfis das bases de dados para treinamentos de redes neurais, comparando os resultados quando da utilização de *datasets* extensos versus *datasets* profundos. Para dois *datasets* com o mesmo número de imagens, o primeiro é considerado mais profundo que o outro se, em média, possuir mais imagens de um mesmo sujeito; o segundo, com menos imagens por indivíduo, é chamado de mais extenso. Constatam os autores que, em geral, conjuntos mais extensos tendem a gerar resultados melhores, indicando ser preferível utilizar mais sujeitos do que ter mais imagens para menos sujeitos, cenário condizente com a proposta de estudo.

3.3 ELABORAÇÃO E EXECUÇÃO DO MÉTODO DE AVALIAÇÃO

Nesta seção serão descritas as principais etapas a serem vencidas para a efetiva realização do projeto, desde a elaboração da proposta do método de avaliação, a escolha das soluções tecnológicas que farão parte dos ensaios, passando pela concepção dos conjuntos de dados que irão nutrir os protótipos e pelas métricas de comparação adotadas, chegando até o estágio de aferição e compilação de resultados, a partir dos quais poderá ser composta uma análise crítica conclusiva.

3.3.1 PROPOSTA DE MÉTODO

Em face do contexto de segurança pública, e com base na revisão de literatura, propõe-se, para avaliação de ferramentas de reconhecimento facial de código aberto, que o método a

ser apresentado obedeça a um fluxograma que deve contemplar as etapas: (1) a denominação do sistema, algoritmo ou *framework* de reconhecimento facial que será submetido à avaliação; (2) construção de dois conjuntos de dados, sendo um de elementos questionados e um de elementos conhecidos; (3) o estabelecimento da proporção entre ambos os conjuntos, para que seja razoavelmente complexa a tarefa de inferir a identidade de um indivíduo desconhecido; (4) a seleção da métrica ou forma de representação da acurácia encontrada.

3.3.1.1 Seleção das tecnologias de reconhecimento facial

De início, foi realizado o levantamento bibliográfico através da execução de um protocolo de revisão sistemática da literatura, cujo processo, critérios (bases consultadas, idiomas, cobertura temporal etc) e resultados encontrados foram previamente formalizados. Com base nos achados ora descritos, definiu-se que a experimentação de tecnologias basear-se-á em três soluções de reconhecimento facial distintas: *VGG-Face*, *Facenet* e *VIPLFaceNet*. Tais candidatas foram encontradas conforme as premissas de inclusão expressas, somando-se que são respaldados pelos melhores resultados constatados na literatura atual.

Em consideração ao fato de que os *frameworks* ora selecionados também disponibilizam os seus modelos pré-treinados em *datasets* públicos, tais modelos serão utilizados e aplicados nos experimentos com a base de dados da Polícia Federal, conforme os princípios de *transfer learning* já explicados.

Neste ponto, é cabível uma ponderação acerca desse aproveitamento de modelos, em detrimento da possibilidade de treinamento da própria rede neural no âmbito da pesquisa: consoante será explanado nas próximas seções, os modelos disponibilizados pelas ferramentas foram treinados em *datasets* contendo milhões de imagens, ou seja, pelo menos uma ordem de magnitude superior aos conjuntos que serão utilizados no presente experimento. De acordo com Cogswell et al. (2015), o acesso a conjuntos de dados rotulados e de larga escala é um dos fatores que promoveu redução significativa na quantidade de *overfitting* das redes neurais, assim permitindo o desempenho que vemos na atualidade. O fenômeno de *overfitting*, conforme explicam Wang et al. (2006), se refere ao problema no qual um modelo é específico demais, ou demasiado sensível, às particularidades dos dados de treinamento utilizados para sua construção – ou seja, o modelo se ajusta bem ao conjunto de dados anteriormente observado, mas é ineficaz na predição de resultados novos; argumenta-se que o uso de dados insuficientes e o uso de dados com vieses são os principais fatores que podem levar ao *overfitting*.

3.3.1.2 Construção dos datasets

Findada a tarefa de seleção das ferramentas, seguiu-se a estruturação dos dois *datasets* a serem consumidos nos ensaios, conforme detalhamento a seguir.

3.3.1.2.1 Galeria (*dataset*) de identidades conhecidas

Para a construção do *dataset* de pessoas conhecidas, foi solicitada autorização à direção da Polícia Federal para obtenção de cópia parcial do banco de dados de emissão de passaportes (objeto do processo administrativo eletrônico SEI nº 08490.003256/2018-43), à magnitude de pelo menos centenas de milhares de imagens, tendo sido cópia de um dos despachos de autorização disposta no Anexo A.

Como produto daquela demanda, foi recebido um conjunto de fotografias da ordem de 250.000 indivíduos em dimensões de 473 x 631 pixels (96 x 96 dpi, 24 bits), totalizando aproximadamente 35 *GigaBytes* de dados, tendo sido os arquivos nomeados conforme o CPF do retratado. Tal montante, conquanto representativo e capaz de conferir robustez à análise dos resultados, não se mostra excessivo ao ponto de inviabilizar os testes por uma eventual falta de recursos computacionais necessários à sua ingestão (processamento, memória e armazenamento). A Figura 13, Figura 14 e Figura 15 ilustram exemplos das fotografias obtidas, para as quais foram obtidas autorizações expressas da exposição.

Figura 13 - Arquivo “84953187172.jpg”.



Fonte: Polícia Federal.

Figura 14 - Arquivo “30967859883.jpg”.



Fonte: Polícia Federal.

Figura 15 - Arquivo “1145792022.jpg”.



Fonte: Polícia Federal.

3.3.1.2.2 Conjunto de prospectos (*dataset* de candidatos desconhecidos)

No intuito de aproximar o experimento proposto das condições reais de uso em investigações policiais, as fotografias para o teste de verificação de identidades foram obtidas da rede social Facebook. Para dimensionamento deste conjunto, foi arbitrada uma proporção de 1:1000 (0,1%) em relação ao *dataset* da galeria, ou seja, foram obtidos 250 prospectos a partir de perfis abertos (públicos), em condições variadas de iluminação, ângulo, pose, aproximação e exposição (ambiente não controlado), todos os quais possuem respectivas imagens de documento de identificação na Galeria.

Como requisito para inclusão neste *dataset*, optou-se pela escolha e adoção de capturas frontais, individuais (e não fotografias de grupo) e sem oclusões (sem partes do rosto encobertas ou cortadas). A Figura 16 e a Figura 17 ilustram amostras das imagens capturadas (também com o uso expressamente autorizado) para as quais tentar-se-á aferir possíveis identificações. A Figura 18 ilustra *thumbnails* (miniaturas) de outras imagens também utilizadas, demonstrando a diversidade das condições de captura.

Figura 16 - Imagem obtida de rede social, inserida no *dataset* de prospectos.



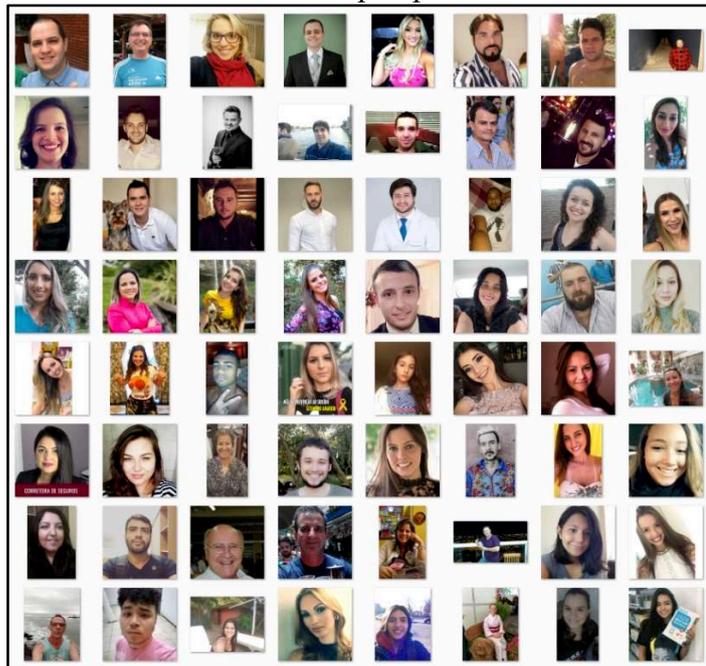
Fonte: Facebook (usuário "Giulliano Togni").

Figura 17 - Imagem obtida de rede social, inserida no *dataset* de prospectos.



Fonte: Facebook (usuário "Guilherme Birckan").

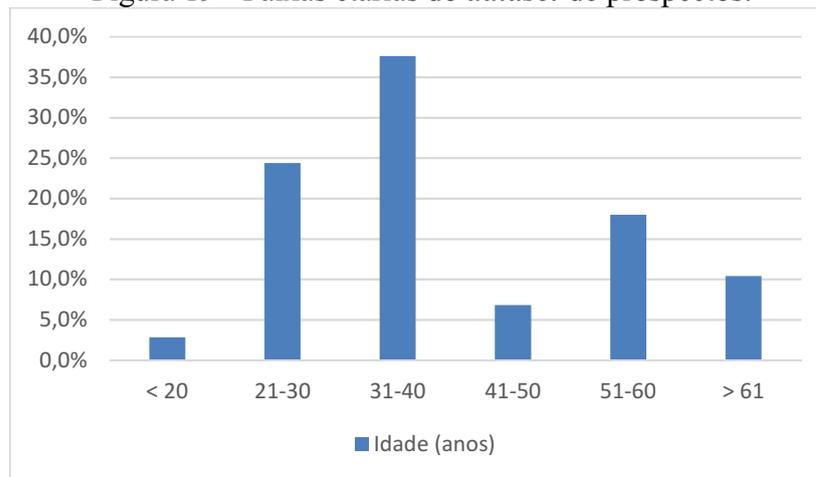
Figura 18 - *Thumbnails* (miniaturas) de outras imagens obtidas de rede social, inseridas no *dataset* de prospectos.



Fonte: Facebook (perfis públicos).

A distribuição demográfica do conjunto de dados de prospectos quanto às faixas etárias foi ilustrada na Figura 19, evidenciando que foram obtidas amostras de indivíduos de todas as idades. Também de forma aleatória, informa-se que foram selecionados 120 homens (48%) e 130 mulheres (52%). Por fim, 21 indivíduos (8,4%) foram retratados utilizando óculos de correção (não solares).

Figura 19 - Faixas etárias do *dataset* de prospectos.



Fonte: elaborada pelo autor

3.3.1.3 Metodologia para avaliação de resultados

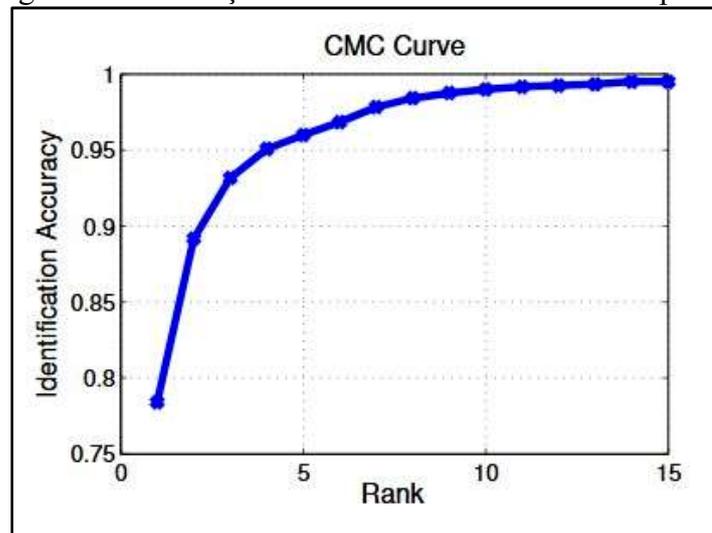
Para a avaliação de desempenho de algoritmos de reconhecimento facial, conforme explicam Becker e Ortiz (2013), normalmente são utilizados os modelos de universo fechado, no qual todos os indivíduos questionados estão também representados no conjunto de imagens de indivíduos conhecidos (ou seja, não há impostores), e de universo aberto, no qual alguns podem não estar (ou seja, em adição à predição da identidade, um índice de confiança também deve ser apresentado). Philips et al. (1997) acrescentam que o modelo de universo fechado permite perguntar-se quão acurado é um algoritmo na identificação de uma imagem questionada; a questão nem sempre é “a melhor resposta é a correta?” mas sim “a resposta correta está nas primeiras N sugestões?”.

O cômputo do *score* de identificação sugerido pelos autores e utilizado no protocolo *FERET Evaluation Methodology for Face-Recognition Algorithms* é adequado ao problema em estudo e será utilizado conforme descrito a seguir. Adotando-se P como um conjunto de prospectos desconhecidos, e $|P|$ como o tamanho de P , será valorado o conjunto P contra a galeria de conhecidos G , onde $G = \{g_1, \dots, g_m\}$ e $P = \{p_1, \dots, p_n\}$ através da comparação dos

scores de similaridade $s_i(\cdot)$ tais que $p_i \in P$ e $g_k \in G$. Para cada imagem prospecta $p_i \in P$, $s_i(\cdot)$ será ordenado para todas as imagens da galeria $g_k \in G$. Assumir-se-á que um *score* de similaridade menor implica maior probabilidade de acerto, ou seja, quanto menor a distância entre duas imagens, maior a chance de que sejam da mesma pessoa. A função $id(i)$ fornece o índice na galeria para a pessoa associada ao prospecto p_i , ou seja, p_i é uma imagem da pessoa em $g_{id(i)}$. Um prospecto p_i estará ranqueado nos top k se $s_i(id(i))$ for um dos k -ésimos menores *scores* $s_i(\cdot)$ para a galeria G .

As estatísticas das soluções analisadas serão representadas em gráficos de curvas do tipo *Cumulative Match Characteristic* (CMC), as quais, de acordo com Bolle et al. (2005), são utilizadas como medida de desempenho de um sistema de identificação 1:n, demonstrando a sua capacidade de *ranking*. Zhao, Han e Shao (2017) corroboram que a CMC é uma métrica de recuperação de informações que captura a capacidade de obtenção da identidade de um prospecto específico dentro dos *top-k* candidatos mais similares. A Figura 20, apresentada por Decann e Ross (2013), ilustra um exemplo de uma curva CMC.

Figura 20 - Ilustração de uma curva CMC de desempenho.



Fonte: DECANN e ROSS (2013, p. 1-8).

3.4 PROTOTIPAÇÃO

A prototipação foi conduzida em sistema operacional Ubuntu 64-bit 14.04 instalado em computador do laboratório de informática do Setor Técnico-Científico da Polícia Federal de Santa Catarina, dotado de processador duplo Xeon ES-2630 v2 @ 2.60GHz, com 64 GB de memória RAM, disco rígido em SSD e placa de vídeo *GigaByte GTX 960*. A seguir, é

apresentado o desenvolvimento dos ensaios utilizando-se das tecnologias selecionadas na Seção 3.3.1.1.

3.4.1 VGG-Face

Para a execução do experimento construído sobre a solução do *Visual Geometry Group* da Universidade de Oxford, foi utilizada uma implementação *open source* baseada em Python e no *framework* Keras com o TensorFlow como *backend*¹. Por sua vez, o modelo utilizado foi aquele denominado *ResNet-50*, o qual foi previamente treinado no *dataset VGGFace2*², conforme proposta por Cao et al. (2018).

Para a etapa de detecção de faces, foi utilizada a biblioteca MTCNN conforme descrita na Seção 2.4. Por fim, para os cálculos de similaridade entre as representações obtidas para cada face, foi utilizada a função de cálculo de distâncias “cosine” do pacote “*scipy.spatial.distance*”, conforme também utilizada nos *test cases* contidos na implementação. O Apêndice A demonstra o código-fonte do experimento, cuja saída é uma lista com cada elemento do conjunto de 250 propostos *P*, seguido da respectiva posição (*rank*) em que a identidade contraparte fora encontrada no conjunto de 250.000 conhecidos da galeria *G*. Adicionalmente, o *script* também salva em arquivos *pickle* as informações processadas, ou seja, os mapas contendo os rótulos (números de CPF) e respectivas representações (*embeddings*) das faces.

3.4.2 FaceNet

O protótipo baseado no algoritmo FaceNet foi construído sobre uma implementação em Python e *TensorFlow* disponível no GitHub³. Por sua vez, o modelo pré-treinado utilizado para a obtenção das representações (*embeddings*) das faces foi aquele denominado “20180402-114759”⁴, o qual usa a arquitetura *Inception ResNet 1* e fora treinado no *dataset VGGFace2*. Este modelo foi selecionado por ter apresentado acurácia ligeiramente superior nos testes do FaceNet sobre o *dataset LFW* do que o outro modelo disponibilizado no âmbito daquele projeto

¹ <https://github.com/rcmalli/keras-vggface.git>

² https://github.com/rcmalli/keras-vggface/releases/download/v2.0/rcmalli_vggface_tf_resnet50.h5

³ <https://github.com/davidsandberg/facenet/>

⁴ <https://drive.google.com/open?id=1EXPBSXwTaqrSC0OhUdXNmKSh9qJUQ55->

(“20180408-102900”), também com a mesma arquitetura, mas treinado com o *dataset* CASIA-WebFace.

Para os cálculos de similaridade entre as representações obtidas para cada face, adotou-se uma função de cômputo de distância euclidiana, registrando-se apenas que a função “cosine” apresentou resultados idênticos. O Apêndice B demonstra o código-fonte do experimento, cuja saída é uma lista com cada elemento do conjunto de 250 propostos P , seguido da respectiva posição (*rank*) em que a identidade contraparte fora encontrada no conjunto de 250.000 conhecidos da galeria G . Adicionalmente, o *script* também salva em arquivos *pickle* as informações processadas, ou seja, os mapas contendo os rótulos (números de CPF) e respectivas representações (*embeddings*) das faces.

3.4.3 VIPLFaceNet

O Software Development Kit (SDK) proposto por Liu et al. (2017), em sua segunda versão, foi obtido a partir do GitHub do projeto SeetaFace⁵. Por sua vez, foi adotado o modelo treinado e disponibilizado no âmbito daquele projeto⁶. O código-fonte do experimento realizado, projetado na linguagem C++, foi disposto no Apêndice C. A saída do programa é uma listagem contendo o valor do cálculo de similaridade do cruzamento entre cada um dos itens de cada *dataset*.

⁵ <https://github.com/seetaface>

⁶ <https://pan.baidu.com/s/1HJj8PEnv3SOu6ZxVpAHPXg>

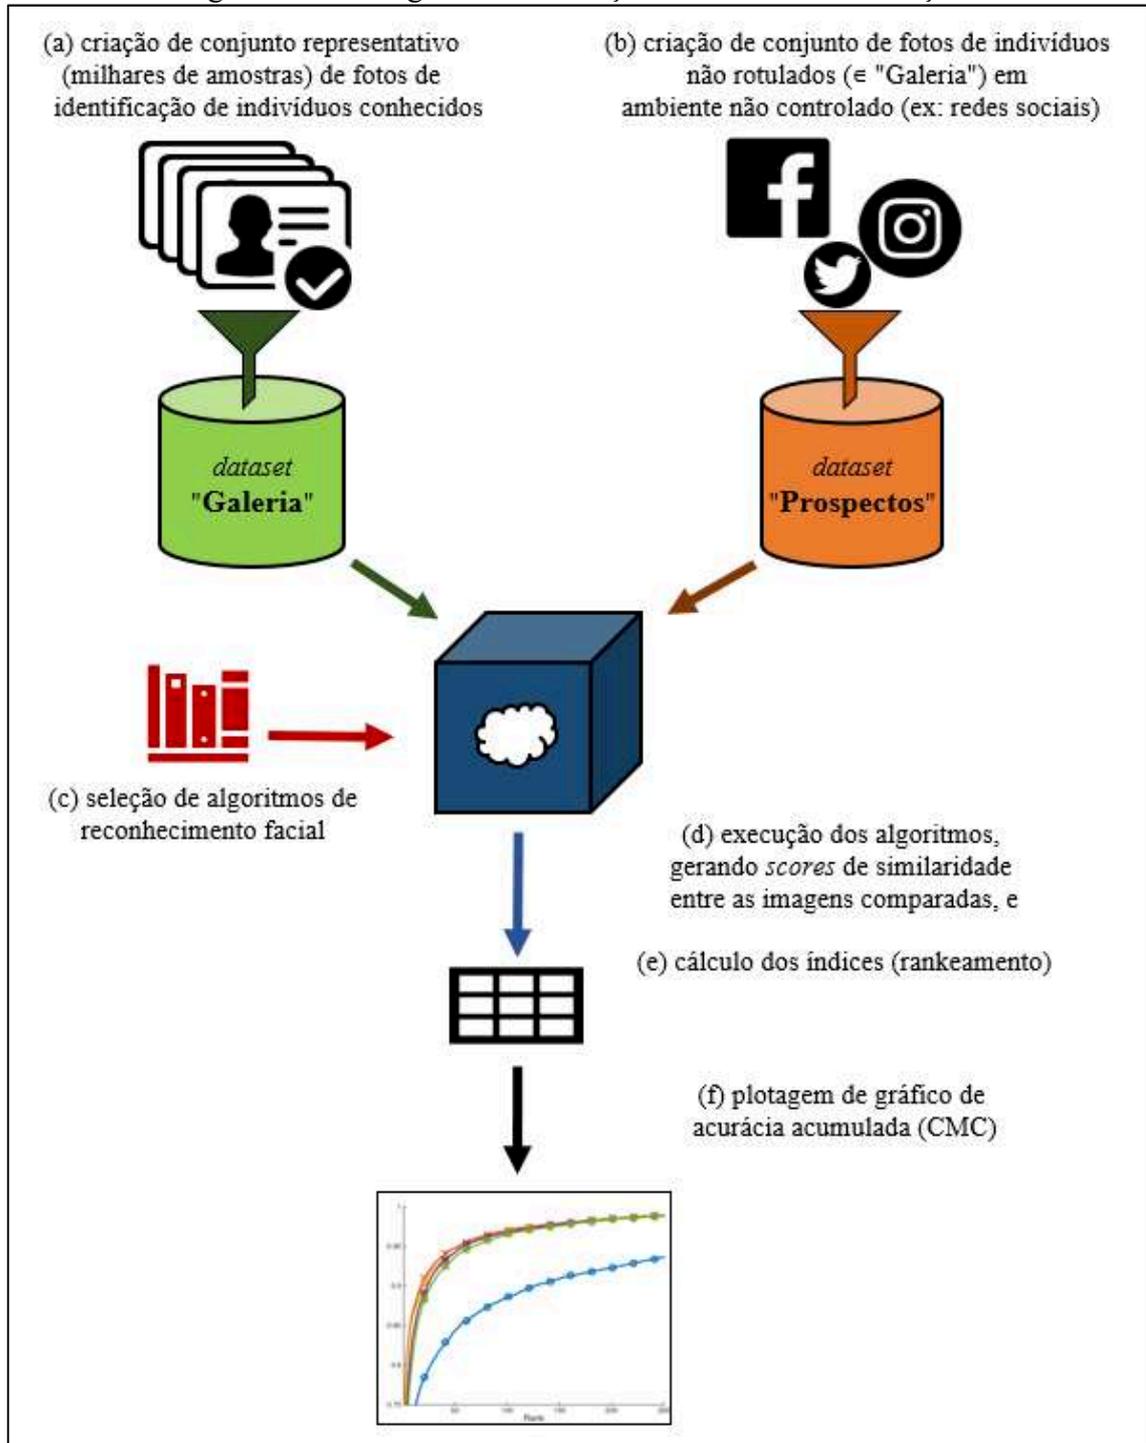
3.5 RESULTADOS

Com base nas premissas elencadas na Seção 3.3.1, foi proposto o método a seguir descrito, ilustrado de forma simplificada na Figura 21:

- a) Constituição de um conjunto de dados, denominado Galeria, contendo imagens de documentos de identificação de indivíduos conhecidos (ex: passaportes ou carteiras nacionais de habilitação), à proporção de uma fotografia única por sujeito, em ambiente controlado (pose frontal, rosto sem oclusões, iluminação adequada). Este conjunto deve ser representativo (ordem de dezenas ou centenas de milhares de amostras), no intuito de efetivamente poder ser utilizado em cálculos de acurácia, mas não excessivo (ordem de milhões de imagens) a ponto de inviabilizar computacionalmente a execução de ensaios.
- b) Constituição de um conjunto de dados, denominado Prospectos, contendo imagens não rotuladas de indivíduos cuja identidade está contida na Galeria, porém fotografados em ambiente não controlado (pose frontal, mas condições variadas de iluminação, plano de fundo, ângulo, expressão facial). Sugere-se que este conjunto possua pelo menos algumas centenas de amostras, e que seja obtido a partir de redes sociais (ex: Facebook ou Instagram), cujas postagens naturalmente apresentam as características citadas, e que também são fontes comuns de robustecimento de investigações policiais.
- c) Seleção de soluções (algoritmos ou *frameworks*) de reconhecimento facial para análise comparativa de resultados.
- d) Execução de algoritmo(s) para extração de *features* (características) de cada uma das imagens, com subsequente comparação entre os itens de cada conjunto (confronto $N \times N$), gerando um *score* de similaridade para cada par de imagens.
- e) Cálculo do índice no qual cada prospecto foi encontrado na galeria, baseado no *score* de similaridade, onde uma menor posição significa maior acurácia.
- f) Plotagem de gráfico de acurácia acumulada, até o limite sugerido de 1/1000 do tamanho do conjunto de dados da Galeria, ou seja, o(s) algoritmo(s) será(ão) avaliado(s) considerando que encontrem identidades na Galeria correspondentes aos Prospectos no limite dos primeiros 0,1% candidatos. Tanto a metodologia de *ranking* como a representação gráfica dos resultados foram descritas em maiores detalhes na

Seção 3.3.1.3. Esclarece-se que a proporção foi sugerida de forma empírica, com base em experimentações, e que pode ser adequada a depender da magnitude dos *datasets* e da expectativa dos resultados.

Figura 21 - Fluxograma de execução do método de avaliação.



Fonte: elaborada pelo autor.

Executados os protótipos construídos, e preliminarmente à apresentação dos resultados, é oportuno um comparativo acerca do desempenho computacional dos algoritmos, ainda que meramente acessório e subjetivo, uma vez que não foram adotadas medidas especiais de otimização de código ou paralelismo/distribuição, e que o comportamento pode variar dependendo do ambiente (*hardware* e sistema operacional), plataforma, linguagem de programação, execução em CPU *versus* GPU, dentre outros. Outrossim, os tempos de execução da etapa de processamento de imagens e extração de representações (*embeddings*), bem como da etapa de comparação de similaridade entre tais representações, foram computados (separadamente, quando possível) a título ilustrativo⁷, resultando nos dados dispostos no Quadro 6.

Quadro 6 - Tempos de execução aproximados dos ensaios.

Algoritmo	Tempo de Processamento (minutos)	Tempo de Comparação (minutos)	Total (minutos)
VGG-Face	9.155	125	9.280
FaceNet	645	20	665
VIPLFaceNet	-	-	360.000

Fonte: elaborado pelo autor.

Os resultados de cada qual dos três ensaios executados, aplicado o método proposto, foram transcritos para o Quadro 7.

⁷ Média aritmética simples e aproximada dos tempos de cada ensaio, após 5 execuções.

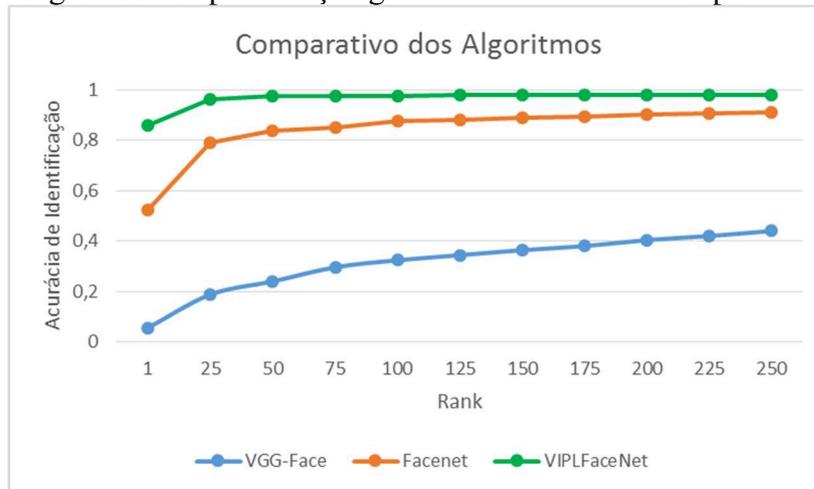
Quadro 7 - Resultados Encontrados para 250 prospectos.

Rank	FaceNet		VIPLFaceNet		VGG-Face	
	Acurácia	Acertos	Acurácia	Acertos	Acurácia	Acertos
1	0,524	131	0,86	215	0,056	14
25	0,788	197	0,96	240	0,188	47
50	0,836	209	0,976	244	0,24	60
75	0,852	213	0,976	244	0,296	74
100	0,876	219	0,976	244	0,324	81
125	0,88	220	0,98	245	0,344	86
150	0,888	222	0,98	245	0,364	91
175	0,892	223	0,98	245	0,38	95
200	0,9	225	0,98	245	0,404	101
225	0,904	226	0,98	245	0,42	105
250	0,912	228	0,98	245	0,44	110

Fonte: elaborado pelo autor.

Constatou-se, dadas as acurácias percebidas pelos três algoritmos testados, que duas das soluções, FaceNet e VIPLFaceNet, tiveram os melhores resultados para o cenário investigativo retratado: enquanto o FaceNet foi capaz de ranquear 91,2% (228 de 250) dos prospectos desconhecidos no topo 0,1% (primeiras 250 identidades) dos indivíduos conhecidos, o VIPLFaceNet atingiu índice de 98% (245 de 250 processadas). Considerando somente o *rank 1*, ou seja, o acerto já na primeira sugestão, o VIPLFaceNet também demonstrou precisão expressiva, tendo sido capaz de aferir a identidade correta em 86% dos casos – muito à frente dos demais concorrentes, que tiveram *scores* de 5% e 52% neste quesito. A Figura 22 apresenta um comparativo dos resultados, onde pode-se visualizar, de forma gráfica, o comportamento da acurácia das três opções analisadas.

Figura 22 - Representação gráfica dos resultados compilados.



Dentre os aspectos positivos do método comparativo proposto, o autor destaca:

- a) a simplicidade de implementação e de automação dos cálculos, uma vez que foi possível a sua imediata aplicação em algoritmos distintos sem a necessidade de adaptações substanciais, assim demonstrando que tecnologias adicionais podem ser facilmente incorporadas aos ensaios para a geração de novos comparativos; e
- b) a adoção de uma representação gráfica para plotagem dos resultados, a qual facilita não só a inteligibilidade das apurações de acurácia, mas também permite um cotejo visual e instantâneo das opções concorrentes.

Por sua vez, dentre os aspectos negativos, também dois pontos podem ser considerados:

- a) a não utilização de variáveis associadas ao desempenho computacional dos algoritmos, uma vez que, conforme visto no Quadro 6, houve grande discrepância nos tempos de execução registrados - em uma aplicação de cunho investigativo, pode ser tolerável um tempo de resposta dilatado, entretanto, já por exemplo em um aplicação de controle de acesso (tal qual o controle migratório), é esperado que o sistema apresente resultados instantâneos; e
- b) a utilização de uma proporção empírica para o estabelecimento dos *rankings* de acurácias, a qual pode (e deve) ser devidamente refinada dependendo do contexto e tamanhos dos *datasets* empregados.

Findada a execução do método apresentado para as três ferramentas selecionadas, e coletados e analisados os resultados, a seguir são apresentadas as conclusões da pesquisa.

4 CONCLUSÃO

Os estudos de reconhecimento facial no âmbito da visão computacional foram favorecidos pela organização de *datasets* públicos de imagens rotuladas, os quais passaram a servir como *benchmarks* e ponto de partida quase que obrigatório para a avaliação e o progresso dos algoritmos. Poucos são os textos que não se favorecem desses denominadores, podendo as abordagens adotar tanto o foco da acurácia como o do desempenho (custo computacional) - ou ambos.

O presente trabalho propôs um método para comparação de tecnologias de reconhecimento facial de código aberto voltado às características de *datasets* da Polícia Federal (imagens de documentos de identificação), no qual, de forma resumida, são sugeridas e enumeradas as etapas de construção de um conjunto de fotos conhecidas e de um conjunto de imagens de desconhecidos, extraídas de ambiente não controlado (redes sociais); a subsequente etapa de execução de algoritmos de reconhecimento facial no qual são cruzados os conjuntos de dados na tentativa de estabelecer identidades para os indivíduos incógnitos, e por fim as etapas de compilação e plotagem dos resultados com base nas acurácias encontradas.

A linha de pesquisa escolhida encontra resguardo no eixo de Informação e Tecnologia da Ciência da Informação, em especial no campo da Recuperação da Informação Multimídia. Conforme detalhado na fundamentação teórica, o componente principal de um sistema de reconhecimento facial é a extração de características (*features*) de uma imagem de rosto, no intuito de alimentar o aprendizado de máquina, efetuar comparações, e oferecer previsões.

Para a realização de ensaios utilizando-se do método exposto, durante o levantamento bibliográfico, realizado por meio de uma revisão sistemática de literatura, foram identificados os *frameworks* postulantes *VGG-Face*, *Facenet* e *VIPLFaceNet*; para os dois primeiros, foram utilizadas implementações em Python, enquanto para o último foi usado um SDK em C++. A prototipação foi descrita na Seção 3.4, enquanto os códigos-fonte foram transcritos para os Apêndices A, B e C. Por sua vez, os resultados encontrados foram dispostos na Seção 3.5.

A partir da acurácia percebida com a execução dos protótipos, foi possível constatar que dois *frameworks*, *FaceNet* e *VIPLFaceNet*, tiveram índices de reconhecimento superiores a 90% na métrica de *ranking* apurada, restando como potenciais candidatos para aprofundamento, otimização e construção de soluções de apoio investigativo para a Polícia Federal, ou ainda como parâmetros comparativos para especificações de requisitos em eventual certame licitatório de aquisição.

Como recomendações para trabalhos futuros, sugere-se a incorporação de variáveis relacionadas ao desempenho computacional, ainda que subjetivas, uma vez que diversas soluções de otimização e paralelismo (tanto em níveis de *hardware* como *software*) podem ser adotadas; além disso, um hipotético *dataset* a ser utilizado em produção tende a uma escala de magnitude que justifica o resguardo quanto à performance. Da mesma forma, enquanto nos ensaios acadêmicos foram adotados indicadores empíricos, em especial para a plotagem e distribuição dos *rankings* de acurácia, sugere-se o aprofundamento desses parâmetros para que reflitam de forma mais fidedigna a relação entre a dimensão dos dados e as expectativas dos usuários finais.

REFERÊNCIAS

- ALPAYDIN, Ethem. **Introduction to machine learning**. MIT press, 2009.
- AMOS, B.; LUDWICZUK, B.; SATYANARAYANAN, M. Openface: A general-purpose face recognition library with mobile applications. **CMU School of Computer Science**, v. 6, 2016.
- ANEJA, Jyoti; DESHPANDE, Aditya; SCHWING, Alexander G. Convolutional image captioning. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. 2018. p. 5561-5570.
- BANSAL, A. et al. The do's and don'ts for cnn-based face verification. In: **Proceedings of the IEEE International Conference on Computer Vision**. [S.l.: s.n.], 2017. p. 2545 – 2554.
- BECKER, Brian; ORTIZ, Enrique. Evaluating open-universe face identification on the web. In: **Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops**. 2013. p. 904-911.
- BELL, Sean et al. Inside-outside net: Detecting objects in context with skip pooling and recurrent neural networks. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. 2016. p. 2874-2883.
- BHOSITHI, W. et al. A Review Paper Between Open Source and Commercial SDK and Performance Comparisons of Face Matchers. In: **2018 International Conference on Engineering, Applied Sciences, and Technology (ICEAST)**. [S.l.: s.n.], 2018. p. 1 – 4.
- BOLLE, R. M. et al. The relation between the ROC curve and the CMC. In: IEEE (Ed.). **Fourth IEEE Workshop on Automatic Identification Advanced Technologies (AutoID'05)**. [S.l.]: IEEE, 2005. p. 15 – 20.
- BORMANN, R. et al. Person recognition for service robotics applications. In: **Humanoid Robots (Humanoids), 2013 13th IEEE-RAS International Conference on**. [S.l.: s.n.], 2013. p. 260 – 267.
- BUHUS, E. R.; GRAMA, L.; SERBU, C. A facial recognition application based on incremental supervised learning. In: **Intelligent Computer Communication and Processing (ICCP), 2017 13th IEEE International Conference on**. [S.l.: s.n.], 2017. p. 279 – 286.
- CAO, Xudong et al. A practical transfer learning algorithm for face verification. In: **Proceedings of the IEEE international conference on computer vision**. 2013. p. 3208-3215.
- CAO, Qiong et al. Vggface2: A dataset for recognising faces across pose and age. In: **2018 13th IEEE International Conference on Automatic Face & Gesture Recognition (FG 2018)**. IEEE, 2018. p. 67-74.
- CIRESAN, Dan Claudiu et al. Flexible, high performance convolutional neural networks for image classification. In: **Twenty-Second International Joint Conference on Artificial Intelligence**. 2011.

COGSWELL, Michael et al. Reducing overfitting in deep networks by decorrelating representations. **arXiv preprint arXiv:1511.06068**, 2015.

DANISMAN, Y. et al. A comparison of eigenvalue methods for principal component analysis. **Appl. Comput. Math**, v. 13, n. 3, p. 316 – 331, 2014.

DA SILVA, Ivan Nunes et al. Artificial neural network architectures and training processes. In: **Artificial neural networks**. Springer, Cham, 2017. p. 8.

DECANN, B.; ROSS, A. Relating roc and cmc curves via the biometric menagerie. In: IEEE (Ed.). **2013 IEEE Sixth International Conference on Biometrics: Theory, applications and systems (btas)**. [S.l.]: IEEE, 2013. p. 1 – 8.

DENG, Li et al. Deep learning: methods and applications. **Foundations and Trends® in Signal Processing**, v. 7, n. 3–4, p. 197-387, 2014.

DESHPANDE, A. et al. Towards Designing an Adaptive Framework for Facial Image Quality Estimation at Edge. In: **2018 3rd International Conference for Convergence in Technology (I2CT)**. [S.l.: s.n.], 2018. p. 1 – 6.

FROME, Andrea et al. Large-scale privacy protection in google street view. In: **2009 IEEE 12th international conference on computer vision**. IEEE, 2009. p. 2373-2380.

GALVÃO, T. F.; PEREIRA, M. G. Revisões sistemáticas da literatura: passos para sua elaboração. **Epidemiologia e Serviços de Saúde**, p. 183 – 184, 2014.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep learning**. MIT press, 2016.

GÜNTHER, M.; SHAFEY, L. E.; MARCEL, S. Face recognition in challenging environments: An experimental and reproducible research survey. **Face recognition across the imaging spectrum**, Springer, Cham, p. 247 – 280, 2016.

HANJALIC, Alan et al. The holy grail of multimedia information retrieval: So close or yet so far away?. **Proceedings of the IEEE**, v. 96, n. 4, p. 541-547, 2008.

HAYKIN, Simon S. et al. **Neural networks and learning machines/Simon Haykin**. New York: Prentice Hall,, 2009.

HERMANS, Alexander; BEYER, Lucas; LEIBE, Bastian. In defense of the triplet loss for person re-identification. **arXiv preprint arXiv:1703.07737**, 2017.

HMANI, M. A.; PETROVSKA-DELACRÉTAZ, D. State-of-the-art face recognition performance using publicly available software and datasets. In: **Advanced Technologies for Signal and Image Processing (ATSIP), 2018 4th International Conference on**. [S.l.]: IEEE, 2018. p. 1 – 6.

HUANG, Gao et al. Trends in extreme learning machines: A review. **Neural Networks**, v. 61, p. 32-48, 2015.

HU, G. et al. When Face Recognition Meets with Deep Learning: an Evaluation of Convolutional Neural Networks for Face Recognition. **CoRR**, abs/1504.02351, 2015. Disponível em: <<http://arxiv.org/abs/1504.02351>>.

HU, J.; PENG, L.; ZHENG, L. XFace: a face recognition system for android mobile phones. In: **Cyber-Physical Systems, Networks, and Applications (CPSNA), 2015 IEEE 3rd International Conference on**. [S.l.]: IEEE, 2015. p. 13 – 18.

IBGE. **Estimativas da população residente no Brasil**. 2018. Disponível em: <ftp://ftp.ibge.gov.br/Estimativas_de_Populacao/Estimativas_2018/estimativa_TCU_2018_20190213.pdf>. Acesso em: 16/04/2019.

JAIN, Anil K.; MAO, Jianchang; MOHIUDDIN, K. Moidin. Artificial neural networks: A tutorial. **Computer**, v. 29, n. 3, p. 31-44, 1996.

JORDAN, Michael I.; MITCHELL, Tom M. Machine learning: Trends, perspectives, and prospects. **Science**, v. 349, n. 6245, p. 255-260, 2015.

KING, D. E. Dlib-ml: A Machine Learning Toolkit. **Journal of Machine Learning Research**, v. 10, p. 1755 – 1758, 2009.

KOVÁCS, Zsolt László. **Redes neurais artificiais**. Editora Livraria da Física, 2002.

LE COADIC, Yves-François. **A ciência da informação**. Briquet de lemos Livros, 1996.

LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep learning. **nature**, v. 521, n. 7553, p. 436, 2015.

LEW, Michael S. et al. Content-based multimedia information retrieval: State of the art and challenges. **ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)**, v. 2, n. 1, p. 1-19, 2006.

LIU, X. et al. VIPLFaceNet: An Open Source Deep Face Recognition SDK. **Frontiers of Computer Science**, v. 11, n. 2, p. 208 – 218, 2017.

LU, T.; WU, M.; LU, T. Face recognition via Gabor and convolutional neural network. In: OPTICS, I. S. for; PHOTONICS (Ed.). **Ninth International Conference on Graphic and Image Processing (ICGIP 2017)**. [S.l.: s.n.], 2018.

MEGHINI, Carlo; SEBASTIANI, Fabrizio; STRACCIA, Umberto. A model of multimedia information retrieval. **Journal of the ACM (JACM)**, v. 48, n. 5, p. 909-970, 2001.

MITCHELL, Tom Michael. **The discipline of machine learning**. Pittsburgh, PA: Carnegie Mellon University, School of Computer Science, Machine Learning Department, 2006.

MONARD, Maria Carolina; BARANAUSKAS, José Augusto. Conceitos sobre aprendizado de máquina. **Sistemas inteligentes-Fundamentos e aplicações**, v. 1, n. 1, p. 32, 2003.

- PAN, Sinno Jialin; YANG, Qiang. A survey on transfer learning. **IEEE Transactions on knowledge and data engineering**, v. 22, n. 10, p. 1345-1359, 2010.
- PARKHI, Omkar M.; VEDALDI, Andrea; ZISSERMAN, Andrew. Deep face recognition. 2015.
- PATTERSON, Josh; GIBSON, Adam. **Deep learning: A practitioner's approach**. "O'Reilly Media, Inc.", p.6, 2017.
- PHILLIPS, P. Jonathon et al. The FERET evaluation methodology for face-recognition algorithms. In: **Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition**. IEEE, 1997. p. 137-143.
- PROVOST, Foster; FAWCETT, Tom. Data science and its relationship to big data and data-driven decision making. **Big data**, v. 1, n. 1, p. 51-59, 2013.
- RANZATO, Marc'Aurelio et al. Unsupervised learning of invariant feature hierarchies with applications to object recognition. In: **2007 IEEE conference on computer vision and pattern recognition**. IEEE, 2007. p. 1-8.
- RICHARDWEBSTER, B. et al. Visual Psychophysics for Making Face Recognition Algorithms More Explainable. In: **Proceedings of the European Conference on Computer Vision (ECCV)**. [S.l.: s.n.], 2018. p. 252 – 270.
- ROSENSTEIN, Michael T. et al. To transfer or not to transfer. In: **NIPS 2005 workshop on transfer learning**. 2005. p. 3.
- SANDBERG, D. **Face recognition using Tensorflow**. 2016. Disponível em: <<https://github.com/davidsandberg/facenet>>. Acesso em: 19/03/2019.
- SARACEVIC, Tefko. Interdisciplinary nature of information science. **Ciência da informação**, v. 24, n. 1, p. 36-41, 1995.
- SCHMIDHUBER, Jürgen. Deep learning in neural networks: An overview. **Neural networks**, v. 61, p. 85-117, 2015.
- SCHROFF, F.; KALENICHENKO, D.; PHILBIN, J. FaceNet: A Unified Embedding for Face Recognition and Clustering. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. [S.l.: s.n.], 2015. p. 815 – 823.
- SURYAPRASAD, J. et al. Parallel implementation and performance evaluation of facial recognition algorithms using open source technologies. In: **Electrical, Electronics, and Optimization Techniques (ICEEOT), International Conference on**. [S.l.]: IEEE, 2016. p. 177 – 182.
- TORREY, Lisa; SHAVLIK, Jude. Transfer learning. In: **Handbook of research on machine learning applications and trends: algorithms, methods, and techniques**. IGI Global, 2010. p. 242-264.

TRIGUEROS, D. S.; MENG, L.; HARTNETT, M. Face Recognition: From Traditional to Deep Learning Methods. **arXiv preprint arXiv:1811.00116**, 2018.

TURAGA, Srinivas C. et al. Convolutional networks can learn to generate affinity graphs for image segmentation. **Neural computation**, v. 22, n. 2, p. 511-538, 2010.

VAN DYK, David A.; MENG, Xiao-Li. The art of data augmentation. **Journal of Computational and Graphical Statistics**, v. 10, n. 1, p. 1-50, 2001.

VEDALDI, A.; LUX, M.; BERTINI, M. MatConvNet: CNNs are also for MATLAB users. **ACM SIGMultimedia Records**, v. 10, n. 1, p. 9 – 9, 2018.

WITTEN, Ian H. et al. **Data Mining: Practical machine learning tools and techniques**. Morgan Kaufmann, 2016.

WALCZAK, Steven. Artificial neural networks. In: **Advanced Methodologies and Technologies in Artificial Intelligence, Computer Simulation, and Human-Computer Interaction**. IGI Global, 2019. p. 40-53.

WANG, Haixun et al. Suppressing model overfitting in mining concept-drifting data streams. In: **Proceedings of the 12th ACM SIGKDD international conference on Knowledge discovery and data mining**. ACM, 2006. p. 736-741.

YASRAB, Robail. SRNET: A Shallow Skip Connection Based Convolutional Neural Network Design for Resolving Singularities. **Journal of Computer Science and Technology**, v. 34, n. 4, p. 924-938, 2019.

ZHANG, K. et al. Joint Face Detection and Alignment Using Multitask Cascaded Convolutional Networks. **IEEE Signal Processing Letters**, v. 23, n. 10, p. 1499 – 1503, 2016.

ZHAO, Jiaojiao; HAN, Jungong; SHAO, Ling. Unconstrained face recognition using a set-to-set distance measure on deep learned features. **IEEE Transactions on Circuits and Systems for Video Technology**, v. 28, n. 10, p. 2679-2689, 2017.

ZHOU, Lina et al. Machine learning on big data: Opportunities and challenges. **Neurocomputing**, v. 237, p. 350-361, 2017.

APÊNDICE A – Código-fonte do ensaio com VGG-Face

```

1. from numpy import expand_dims
2. from matplotlib import pyplot
3. from PIL import Image
4. from numpy import asarray
5. from scipy.spatial.distance import cosine
6. from mtcnn.mtcnn import MTCNN
7. from keras_vggface.vggface import VGGFace
8. from keras_vggface.utils import preprocess_input
9. import os, sys, pickle, operator
10.
11. def extract_face(filename, required_size=(224, 224)):
12.     pixels = pyplot.imread(filename)
13.     detector = MTCNN()
14.     results = detector.detect_faces(pixels)
15.     x1, y1, width, height = results[0]['box']
16.     x2, y2 = x1 + width, y1 + height
17.     face = pixels[y1:y2, x1:x2]
18.     image = Image.fromarray(face)
19.     image = image.resize(required_size)
20.     face_array = asarray(image)
21.     return face_array
22.
23. def process_dir(input_dir):
24.     model = VGGFace(model='resnet50')
25.     labels_and_embeddings = {}
26.     filenames = sorted(os.listdir(input_dir))
27.     counter = 0
28.     for filename in filenames:
29.         counter += 1
30.         print('Processing %s %s/%s' % (str(counter), input_dir, filename))
31.         try:
32.             label = os.path.splitext(filename)[0]
33.             file_url = input_dir + '/' + filename
34.             face_pixels = extract_face(file_url)
35.             face_pixels = face_pixels.astype('float32')
36.             samples = expand_dims(face_pixels, axis=0)
37.             samples = preprocess_input(samples, version=2)
38.             labels_and_embeddings[label] = model.predict(samples)
39.         except:
40.             print('[ERROR] ', sys.exc_info()[0], ' occurred.')
41.     return labels_and_embeddings
42.
43. fb_labels_and_embeddings = process_dir('datasets/facebook_250')
44. with open('pkl/facebook_250_labels_and_embeddings.pkl', 'wb') as pkl_out:
45.     pickle.dump(fb_labels_and_embeddings, pkl_out)
46.
47. pp_labels_and_embeddings = process_dir('datasets/passaporte_250000')
48. with open('pkl/passaporte_250000_labels_and_embeddings.pkl', 'wb') as pkl_out:
49.     pickle.dump(pp_labels_and_embeddings, pkl_out)
50.
51. for fb_label, fb_embedding in fb_labels_and_embeddings.items():
52.     distances = {}
53.     for pp_label, pp_embedding in pp_labels_and_embeddings.items():
54.         distances[pp_label] = cosine(fb_embedding, pp_embedding)
55.     sorted_distances = sorted(distances.items(), key = operator.itemgetter(1))
56.     rank = 0
57.     for k, v in sorted_distances:
58.         rank += 1
59.         if k == fb_label:
60.             print('%s,%s' % (k, str(rank)))
61.             break

```

APÊNDICE B – Código-fonte do ensaio com FaceNet

```

1. import tensorflow as tf
2. import os, operator, pickle, glob
3. import numpy as np
4. from imageio import imread
5. from skimage.transform import resize
6. import facenet
7. from align import detect_face
8. from datetime import datetime
9.
10. model_filename = './models/20180402-114759/20180402-114759.pb'
11. gallery_dir = './../datasets/passaporte_250000'
12. prospects_dir = './../datasets/facebook_250'
13.
14. MARGIN = 44
15. IMAGE_SIZE = 160
16. MIN_FACE_SIZE = 90
17.
18. def detect_faces(img):
19.     threshold = [0.6, 0.7, 0.7]
20.     factor = 0.709
21.     return detect_face.detectFace(img, MIN_FACE_SIZE, pnet, mnet, onet, threshold, factor)
22.
23. def crop_and_align(img, bounding_boxes, face_index = 0):
24.     img_size = np.asarray(img.shape)[0:2]
25.     det = np.squeeze(bounding_boxes[face_index, 0:4])
26.     bb = np.zeros(4, dtype=np.int32)
27.     bb[0] = np.maximum(det[0]-MARGIN/2, 0)
28.     bb[1] = np.maximum(det[1]-MARGIN/2, 0)
29.     bb[2] = np.minimum(det[2]+MARGIN/2, img_size[1])
30.     bb[3] = np.minimum(det[3]+MARGIN/2, img_size[0])
31.     cropped = img[bb[1]:bb[3], bb[0]:bb[2], :]
32.     aligned = resize(cropped, (IMAGE_SIZE, IMAGE_SIZE))
33.     return facenet.prewhiten(aligned)
34.
35. def load_and_align_images(filelist):
36.     images = {}
37.     for filename in filelist:
38.         image = imread(filename)
39.         bounding_boxes, _ = detect_faces(image)
40.         if len(bounding_boxes) < 1:
41.             print('WARNING - Did not find a face in %s' % filename)
42.             continue
43.         label = os.path.splitext(os.path.basename(filename))[0]
44.         images[label] = crop_and_align(image, bounding_boxes)
45.     return images
46.
47. def break_list_into_chunks(lst, n):
48.     return [lst[i * n:(i + 1) * n] for i in range((len(lst) + n - 1) // n)]
49.
50. def get_embeddings_from_images(input_dir):
51.     batch_size = 2500
52.     filenames = glob.glob(input_dir + '/*.jpg')
53.     filenames = break_list_into_chunks(filenames, batch_size)
54.     labels_embeddings = {}
55.     for i, batch_filenames in enumerate(filenames):
56.         print('Processing batch # %s of %s' % (str(i), str(len(filenames))))
57.         batch_images = load_and_align_images(batch_filenames)
58.         feed_dict = {images_placeholder: batch_images.values(), phase_train_placeholder: False}
59.         batch_embeddings = tf_session.run(embeddings, feed_dict=feed_dict)
60.         batch_labels_embeddings = {}
61.         for j, label in enumerate(batch_images):
62.             batch_labels_embeddings[label] = batch_embeddings[j]

```

```

63.     pkl_filename = os.path.basename(input_dir) + '-embeddings-' + str(i) + '.pkl'
64.     with open('../pkl-facenet/' + pkl_filename, 'wb') as pkl_out:
65.         pickle.dump(batch_labels_embeddings, pkl_out)
66.     labels_embeddings.update(batch_labels_embeddings)
67.     return labels_embeddings
68.
69. def calc_distance(face1, face2):
70.     return np.sqrt(np.sum(np.square(np.subtract(face1, face2))))
71.
72. with tf.Graph().as_default():
73.
74.     gpu_options = tf.GPUOptions(per_process_gpu_memory_fraction=0.9)
75.     with tf.Session(config=tf.ConfigProto(gpu_options=gpu_options)) as tf_session:
76.
77.         facenet.load_model(model_filename)
78.
79.         images_placeholder = tf.get_default_graph().get_tensor_by_name('input:0')
80.         embeddings = tf.get_default_graph().get_tensor_by_name('embeddings:0')
81.         phase_train_placeholder = tf.get_default_graph().get_tensor_by_name('phase_train:0')
82.         pnet, met, onet = detect_face.create_mtcnn(tf_session, None)
83.
84.         print('Processing prospects on %s' % datetime.now().strftime('%d/%m/%Y %H:%M:%S'))
85.         prospects_embeddings = get_embeddings_from_images(prospects_dir)
86.         with open('../pkl-facenet/prospects-embeddings.pkl', 'wb') as pkl_out:
87.             pickle.dump(prospects_embeddings, pkl_out)
88.
89.         print('Processing gallery on %s' % datetime.now().strftime('%d/%m/%Y %H:%M:%S'))
90.         gallery_embeddings = get_embeddings_from_images(gallery_dir)
91.
92.         print('Calculating distances on %s' % datetime.now().strftime('%d/%m/%Y %H:%M:%S'))
93.
94.         for fb_label, fb_embedding in prospects_embeddings.items():
95.             distances = {}
96.             print('Finding best rank for ' + fb_label)
97.             for pp_label, pp_embedding in gallery_embeddings.items():
98.                 distances[pp_label] = calc_distance(fb_embedding, pp_embedding)
99.             sorted_distances = sorted(distances.items(), key = operator.itemgetter(1))
100.            rank = 0
101.            for k, v in sorted_distances:
102.                rank += 1
103.                if k == fb_label:
104.                    print('%s,%s' % (k, str(rank)))
105.                    break

```

APÊNDICE C – Código-fonte do ensaio com VIPLFaceNet

```

1. #include <iostream>
2. #include <experimental/filesystem>
3. #include <seeta/FaceRecognizer.h>
4. #include <seeta/FaceDetector2.h>
5. #include <seeta/PointDetector2.h>
6. #include <seeta/Struct_cv.h>
7. #include <opencv2/core/core.hpp>
8. #include <opencv2/highgui/highgui.hpp>
9. #include <opencv2/imgproc/imgproc.hpp>
10.
11. namespace fs = std::experimental::filesystem;
12.
13. float compare_files(seeta::FaceDetector2 &FD, seeta::PointDetector2 &PD,
14.     seeta::FaceRecognizer2 &FR, const std::string &filename1, const std::string &filename2) {
15.     int numDetectedFaces;
16.     cv::Mat mat1 = cv::imread(filename1);
17.     seeta::cv::ImageData image1 = mat1;
18.     SeetaRect *face1 = FD.Detect(image1, &numDetectedFaces);
19.     if (numDetectedFaces < 1) {
20.         return 0.0;
21.     }
22.     SeetaPointF points1[5];
23.     PD.DetectEx(image1, *face1, points1);
24.     if (!points1) {
25.         return 0.0;
26.     }
27.     cv::Mat mat2 = cv::imread(filename2);
28.     seeta::cv::ImageData image2 = mat2;
29.     SeetaRect *face2 = FD.Detect(image2, &numDetectedFaces);
30.     if (numDetectedFaces < 1) {
31.         return 0.0;
32.     }
33.     SeetaPointF points2[5];
34.     PD.DetectEx(image2, *face2, points2);
35.     if (!points2) {
36.         return 0.0;
37.     }
38.     return FR.Compare(image1, points1, image2, points2);
39. }
40.
41. int main(int argc, char *argv[]) {
42.     if (argc != 3) {
43.         std::cout << "Usage: VIPLFACENET <prospects_dir> <gallery_dir>" << std::endl;
44.         return -1;
45.     }
46.     seeta::FaceRecognizer2 FR("./bindata/SeetaFaceRecognizer2.0.ats");
47.     seeta::FaceDetector2 FD("./bindata/SeetaFaceDetector2.0.ats");
48.     seeta::PointDetector2 PD("./bindata/SeetaPointDetector2.0.pts5.ats");
49.
50.     int count1 = 1;
51.     for (const auto & entry1 : fs::directory_iterator(argv[1])) {
52.         int count2 = 1;
53.         for (const auto & entry2 : fs::directory_iterator(argv[2])) {
54.             float score = compare_files(FD, PD, FR, entry1.path(), entry2.path());
55.             std::cout << count1 << " " << count2++ << " " << entry1.path().filename() << " "
56.                 << entry2.path().filename() << " " << score << std::endl;
57.         }
58.         count1 ++;
59.     }
60.     return 0;
61. }

```

APÊNDICE D – Trabalhos excluídos na revisão de literatura

Crit.	Autores	Título	Publicação	Ano
2	Junjue Wang, Brandon Amos, Anupam Das, Padmanabhan Pillai, Norman Sadeh, Mahadev Satyanarayanan	Enabling Live Video Analytics with a Scalable and Privacy-Aware Framework	ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)	2018
2	Zeeshan Shaukat, Juan Fang, Muhammad Azeem, Faheem Akhtar, Saqib Ali	Cloud Based Face Recognition for Google Glass	Proceedings of the 2018 International Conference on Computing and Artificial Intelligence	2018
2	R. Senthilkumar, R.K. Gnanamurthy	A New Approach in Face Recognition: Duplicating Facial Images Based on Correlation Study	Proceedings of the 11th International Knowledge Management in Organizations Conference on the changing face of Knowledge Management Impacting Society	2016
2	Junjue Wang, Brandon Amos, Anupam Das, Padmanabhan Pillai, Norman Sadeh, Mahadev Satyanarayanan	A Scalable and Privacy-Aware IoT Service for Live Video Analytics	Proceedings of the 8th ACM on Multimedia Systems Conference	2017
1	BM Kwon, KH Lee	An Introduction to Face-recognition Methods and Its Implementation in Software Applications	International Journal of Information Technology and Management	2018
1	Naser Hossein Motlagh, Miloud Bagaa, Tarik Taleb	UAV-Based IoT Platform: A Crowd Surveillance Use Case	IEEE Communications Magazine	2017
1	Cau Zaghetto, Luiz Henrique M. Aguiar, Alexandre Zaghetto, Clá G. Ralha, Flavio de Barros Vidal	Agent-based Framework to Individual Tracking in Unconstrained Environments	Expert Systems with Applications: An International Journal	2017
2	A. Ragab, Xavier de Carné de Carnavalet, Soumaya Yacout, Mohamed-Salah Ouali	Face recognition using multi-class Logical Analysis of Data	Pattern Recognition and Image Analysis	2017
1	Francisco Airtton Silva, Paulo Maciel, Eder Santana, Rubens Matos, Jamilson Dantas	Mobile cloud face recognition based on smart cloud ranking	Computing	2017
2	Seon Ho Oh, Geon-Woo Kim, Kyung-Soo Lim	Compact deep learned feature-based face recognition for Visual Internet of Things	The Journal of Supercomputing	2017
2	Guanhao Chen, Yanqing Shao, Chaowei Tang, Zhuoyi Jin, Jinkun Zhang	Deep transformation learning for face recognition in the unconstrained scene	Machine Vision and Applications	2018
2	K. Sasirekha, K. Thangavel	Optimization of K-nearest neighbor using particle swarm optimization for face recognition	Neural Computing and Applications	2018
1	Suchitra Agrawal, Rajeev Kumar Singh, Uday Pratap Singh, Sanjeev Jain	Biogeography particle swarm optimization based counter propagation network for sketch based face recognition	Multimedia Tools and Applications	2018
1	Martin Strunz	Open Source Biometric	Datenschutz und Datensicherheit - DuD	2017
1	Ilaria Bartolini, Marco Patella	A general framework for real-time analysis of massive multimedia streams	Multimedia Systems	2018
2	V. D. Ambeth Kumar, V. D. Ashok Kumar, S. Malathi, K. Vengatesan, M. Ramakrishnan	Facial Recognition System for Suspect Identification Using a Surveillance Camera	Pattern Recognition and Image Analysis	2018
1	Benjamin Valdés Aguirre, Jorge A. Ramírez Uresti, Benedict du Boulay	An Analysis of Student Model Portability	International Journal of Artificial Intelligence in Education	2016
1	Chinnaiah Valliyammai, Ramalingam Devakunchari	Distributed and scalable Sybil identification based on nearest neighbour approximation using big data analysis techniques	Cluster Computing	2018
1	Haijun Zhang, Yuzhu Ji, Wang Huang, Linlin Liu	Sitcom-star-based clothing retrieval for video advertising: a deep learning framework	Neural Computing and Applications	2018
1	Adam Wójtowicz, Jacek Chmielewski	Technical feasibility of context-aware passive payment authorization for physical points of sale	Personal and Ubiquitous Computing	2017
1	Jin-Hua Tao, Zi-Dong Du, Qi Guo, Hui-Ying Lan, Lei Zhang, Sheng-Yuan Zhou, Ling-Jie Xu, Cong Liu, Hai-Feng Liu, Shan Tang, Allen Rush, William Chen, Shao-Li Liu, Yun-Ji Chen, Tian-Shi Chen	BenchIP: Benchmarking Intelligence Processors	Journal of Computer Science and Technology	2018
1	Christos Sagonas, Yannis Panagakis, Stefanos Zafeiriou, Maja Pantic	Robust Statistical Frontalization of Human and Animal Faces	International Journal of Computer Vision	2017
1	Grigorios G. Chrysos, Epameinondas Antonakos, Patrick Snape, Akshay Asthana, Stefanos Zafeiriou	A Comprehensive Performance Evaluation of Deformable Face Tracking "In-the-Wild"	International Journal of Computer Vision	2018
1	Kuo-Hui Yeh, Nai-Wei Lo, Chun-Kai Wang	A robust NFC-based personalized IPTV service system	Multimedia Tools and Applications	2018
1	Zepeng Wang, Hu Zhen-tao, Peng Shu, Ting Chen	Real-time mask detection in multimedia environment	Multimedia Tools and Applications	2017
1	Johann Poignant, Hervé Bredin, Claude Barras	Multimodal person discovery in broadcast TV: lessons learned from MediaEval 2015	Multimedia Tools and Applications	2017
1	Markus Mühling, Manja Meister, Nikolaus Korfhage, Jörg Wehling, Angelika Hörth, Ralph Ewerth, Bernd Freisleben	Content-based video retrieval in historical collections of the German Broadcasting Archive	International Journal on Digital Libraries	2018
1	Binbin Yong, Gaofeng Zhang, Huaming Chen, Qingguo Zhou	Intelligent monitor system based on cloud and convolutional neural networks	The Journal of Supercomputing	2017
1	George Awad Wessel Kraaij, Paul Over, Shin'ichi Satoh	Instance search retrospective with focus on TRECVID	International Journal of Multimedia Information Retrieval	2017
1	Marcello Ienca	Democratizing cognitive technology: a proactive approach	Ethics and Information Technology	2018
1	Khurram Zeeshan Haider, Kaleem Razzaq Malik, Shehzad Khalid, Tabassam Nawaz, Sohail Jabbar	Deepgender: real-time gender classification using deep learning for smartphones	Journal of Real-Time Image Processing	2017
1	Qi Luo, Aswathy Nair, Mark Grechanik, Denys Poshyvanyk	FOREPOST: finding performance problems automatically with feedback-directed learning software testing	Empirical Software Engineering	2017
1	Christine E. King, Majid Sarrafzadeh	A Survey of Smartwatches in Remote Health Monitoring	Journal of Healthcare Informatics Research	2018
1	Cristina Palmero, Albert Clapés, Chris Bahnsen, Andreas Mogelmoose, Thomas B. Moeslund, Sergio Escalera	Multi-modal RGB-Depth-Thermal Human Body Segmentation	International Journal of Computer Vision	2016
1	Anupam Banerjee, Sumana Basu, Subhadip Basu, Mita Nasipuri	ARTEM: a new system for human authentication using finger vein images	Multimedia Tools and Applications	2018
1	Reza Syahroel Ghufuran, Jenq-Shiou Leu, Setya Widyanawan Prakosa	Improving the age estimation accuracy by a hybrid optimization scheme	Multimedia Tools and Applications	2018
1	Iuliia Kotscheruba, John K. Tsotsos	40 years of cognitive architectures: core cognitive abilities and practical applications	Artificial Intelligence Review	2018
1	Hwin Dol Park, Ok-Gee Min, Yong-Ju Lee	Scalable architecture for an automated surveillance system using edge computing	The Journal of Supercomputing	2017

1	Wei Lu, Jiajia Hou, Ying Yan, Meihui Zhang, Xiaoyong Du, Thomas Moscibroda	MSQL: efficient similarity search in metric spaces using SQL	The VLDB Journal	2017
1	Yu Zhang, Morteza Saberi, Elizabeth Chang	A semantic-based knowledge fusion model for solution-oriented information network development: a case study in intrusion detection field	Scientometrics	2018
1	Yong-hong Tian, Xi-lin Chen, Hong-kai Xiong, Hong-liang Li, Li-rong Dai, Jing Chen, Jun-liang Xing, Jing Chen, Xi-hong Wu, Wei-min Hu, Yu Hu, Tie-jun Huang, Wen Gao	Towards human-like and transhuman perception in AI 2.0: a review	Frontiers of Information Technology & Electronic Engineering	2017
1	Hamed Vahdat-Nejad, Shaghayegh Izadpanah, Shaghayegh Ostadi-Eilaki	Context-aware cloud-based systems: design aspects	Cluster Computing	2017
1	Javier J. Salmerón-García, Sjoerd van den Dries, Fernando Díaz-del-Río, Arturo Morgado-Estevez, Jose Luis Sevillano-Ramos, M. J. G. van de Molengraft	Towards a cloud-based automated surveillance system using wireless technologies	Multimedia Systems	2017
1	Juzheng Zhang, Jianmin Zheng, Nadia Magnenat Thalmann	MCAEM: mixed-correlation analysis-based episodic memory for companion-user interactions	The Visual Computer	2018
1	Tong Hao, Qian Wang, Dan Wu, Jin-Sheng Sun	Adaptive recommendation for photo pose via deep learning	Multimedia Tools and Applications	2018
1	Miguel Bordallo López, Alejandro Nieto, Jani Boutellier, Jari Hannuksela, Olli Silvén	Evaluation of real-time LBP computing in multiple architectures	Journal of Real-Time Image Processing	2017
1	Sonia Shahzadi, Muddesar Iqbal, Tasos Dagiuklas, Zia Ul Qayyum	Multi-access edge computing: open issues, challenges and future perspectives	Journal of Cloud Computing	2017
1	Heitor M. Gomes, Albert Bifet, Jesse Read, Jean Paul Barddal, Fabrício Enembreck, Bernhard Pfahringer, Geoff Holmes, Talel Abdesslem	Adaptive random forests for evolving data stream classification	Machine Learning	2017
1	Leslie F. Sikos	RDF-powered semantic video annotation tools with concept mapping to Linked Data for next-generation video indexing: a comprehensive review	Multimedia Tools and Applications	2017
1	Varvana Myllärniemi, Juha Savolainen, Mikko Raatikainen, Tomi Männistö	Performance variability in software product lines: proposing theories from a case study	Empirical Software Engineering	2016
1	Oscar Cabrera, Xavier Franch, Jordi Marco	3LConOnt: a three-level ontology for context modelling in context-aware computing	Software & Systems Modeling	2017
1	Abdullah Alsaleh	Can cloudlet coordination support cloud computing infrastructure?	Journal of Cloud Computing	2018
1	Nadia Alshahwan, Xinbo Gao, Mark Harman, Yue Jia, Ke Mao, Alexander Mols, Taijin Tei, Ilya Zorin	Deploying Search Based Software Engineering with Sapienz at Facebook	Search-Based Software Engineering	2018
1	Konrad Jackowski, Boguslaw Cyganek	A learning-based colour image segmentation with extended and compact structural tensor feature representation	Pattern Analysis and Applications	2017
1	Peng-Cheng Huang, Chin-Chen Chang, Yung-Hui Li, Yanjun Liu	Efficient access control system based on aesthetic QR code	Personal and Ubiquitous Computing	2018
1	Surekha Thota, Ravi Prakash Reddy Induri, Raghavendra Kune	Split key management framework for Open Stack Swift object storage cloud	CSI Transactions on ICT	2017
1	Yongzhe Zheng, Zhixin Li, Canlong Zhang	A hybrid architecture based on CNN for cross-modal semantic instance annotation	Multimedia Tools and Applications	2018
1	Lianbing Deng, Daming Li, Xiang Yao, David Cox, Haoxiang Wang	Mobile network intrusion detection for IoT system based on transfer learning algorithm	Cluster Computing	2018
1	Zhengwei Huang, Wentao Xue, Qirong Mao, Yongzhao Zhan	Unsupervised domain adaptation for speech emotion recognition using PCANet	Multimedia Tools and Applications	2017
2	G. Ososkov, P. Goncharov	Shallow and deep learning for image classification	Optical Memory and Neural Networks	2017
1	Chunjuan Bo, Junxing Zhang, Changhong Liu, Qiang Yao	Online visual tracking based on subspace representation with continuous occlusion modeling	Multimedia Systems	2017
1	Yanping Ma, Dongbao Yang, Hongtao Xie, Jian Yin	Supervised deep hashing for image content security	Multimedia Tools and Applications	2017
1	Qiang Li, Haiyan Fu, Xiangwei Kong, Qi Tian	Deep hashing with top similarity preserving for image retrieval	Multimedia Tools and Applications	2018
1	Alfredo Cuesta-Infante, Francisco J. García, Juan J. Pantrigo, Antonio S. Montemayor	Pedestrian detection with LeNet-like convolutional networks	Neural Computing and Applications	2017
1	Saad Ezzini, Ismail Berrada, Mounir Ghogho	Who is behind the wheel? Driver identification and fingerprinting	Journal of Big Data	2018
1	Zhi Yang, Wei Yu, Pengwei Liang, Hanqi Guo, Likun Xia, Feng Zhang, Yong Ma, Jiayi Ma	Deep transfer learning for military object recognition under small training set condition	Neural Computing and Applications	2018
1	Giuseppe Lisanti, Svebor Karaman, Daniele Pezzatini, Alberto Del Bimbo	A multi-camera image processing and visualization system for train safety assessment	Multimedia Tools and Applications	2018
1	Benaoumeur Senouci, Imen Charfi, Barthelemy Heyrman, Julien Dubois, Johel Miteran	Fast prototyping of a SoC-based smart-camera: a real-time fall detection case study	Journal of Real-Time Image Processing	2016
1	Dong Wang, Meng Yi, Fan Yang, Erik Blasch, Carolyn Sheaff, Genshe Chen, Haibin Ling	Online single target tracking in WAMI: benchmark and evaluation	Multimedia Tools and Applications	2018
1	Sergio G. Pfleger, Patricia D. M. Plentz, Rodrigo C. O. Rocha, Alyson D. Pereira, Márcio Castro	Real-time video denoising on multicores and GPUs with Kalman-based and Bilateral filters fusion	Journal of Real-Time Image Processing	2017
1	Anja Keskinarkaus, Sami Huttunen, Antti Siipo, Jukka Holappa, Magda Laszlo, Ilkka Juuso, Eero Väyrynen, Janne Heikkilä, Matti Lehtihalmes, Tapio Seppänen, Seppo Laukka	MORE - a multimodal observation and analysis system for social interaction research	Multimedia Tools and Applications	2016
1	Shivendra Shivani, Shailendra Tiwari	Simulation of intelligent target hitting in obstructed path using physical body animation and genetic algorithm	Multimedia Tools and Applications	2018
1	Ben De Meester, Ruben Verborgh, Pieter Pauwels, Wesley De Neve, Erik Mannens, Rik Van de Walle	Towards robust and reliable multimedia analysis through semantic integration of services	Multimedia Tools and Applications	2016
1	G. Iannizzotto; L. L. Bello; A. Nucita; G. M. Grasso	A Vision and Speech Enabled, Customizable, Virtual Assistant for Smart Environments	2018 11th International Conference on Human System Interaction (HSI)	2018
1	J. M. Silva; A. Guerra; J. F. Silva; E. Pinho; C. Costa	Face De-Identification Service for Neuroimaging Volumes	2018 IEEE 31st International Symposium on Computer-Based Medical Systems (CBMS)	2018
1	F. Wang; X. Chen; D. Wang; B. Yang	An improved image-based iris-tracking for driver fatigue detection system	2017 36th Chinese Control Conference (CCC)	2017
2	P. Tungjitsirisun; W. Pechsuwanrunsee; P. Siripongwutikorn	Wireless door access system with face verification	2016 Fifth ICT International Student Project Conference (ICT-ISPC)	2016
1	Y. Li; Y. Chen; T. Lan; G. Venkataramani	MobiQoR: Pushing the Envelope of Mobile Edge Computing Via Quality-of-Result Optimization	2017 IEEE 37th International Conference on Distributed Computing Systems (ICDCS)	2017

1	M. Kowalski; Z. Nasarzewski; G. Galinski; P. Garbat	HoloFace: Augmenting Human-to-Human Interactions on HoloLens	2018 IEEE Winter Conference on Applications of Computer Vision (WACV)	2018
1	J. O'Dwyer; R. Flynn; N. Murray	Continuous affect prediction using eye gaze and speech	2017 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)	2017
1	A. Băltoiu; L. Petrică; A. Dinculescu; C. Vizitiu	Framework for an embedded emotion assessment system for space science applications	2017 E-Health and Bioengineering Conference (EHB)	2017
1	J. Güttler; C. Georgoulas; T. Bock	Contactless fever measurement based on thermal imagery analysis	2016 IEEE Sensors Applications Symposium (SAS)	2016
1	M. R. Pawar; I. Rizvi	IoT Based Embedded System for Vehicle Security and Driver Surveillance	2018 Second International Conference on Inventive Communication and Computational Technologies (ICICCT)	2018
1	F. Anda; D. Lillis; N. Le-Khac; M. Scanlon	Evaluating Automated Facial Age Estimation Techniques for Digital Forensics	2018 IEEE Security and Privacy Workshops (SPW)	2018
1	B. Gite; K. Nikhal; F. Palnak	Evaluating facial expressions in real time	2017 Intelligent Systems Conference (IntelliSys)	2017
1	V. Razdan; A. Modi; S. Dumbare; R. Jobanputra	YCSB+T: Benchmark for transactional databases and performance	2017 International conference of Electronics, Communication and Aerospace Technology (ICECA)	2017
1	T. Gerig; A. Morel-Forster; C. Blumer; B. Egger; M. Luthi; S. Schoenborn; T. Vetter	Morphable Face Models - An Open Framework	2018 13th IEEE International Conference on Automatic Face & Gesture Recognition (FG 2018)	2018
1	J. R. Balbin; J. N. J. Pinugu; A. J. S. Basco; M. B. Cabanada; P. M. V. Gonzales; J. C. C. Marasigan; M. M. Sejera	Development of scientific system for assessment of post-traumatic stress disorder patients using physiological sensors and feature extraction for emotional state analysis	2017 IEEE 9th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management (HNICEM)	2017
1	C. Yao; X. Wang; Z. Zheng; G. Sun; L. Song	EdgeFlow: Open-Source Multi-layer Data Flow Processing in Edge Computing for 5G and Beyond	IEEE Network	2018
1	P. Huber; P. Kopp; W. Christmas; M. Rätzsch; J. Kittler	Real-Time 3D Face Fitting and Texture Fusion on In-the-Wild Videos	IEEE Signal Processing Letters	2017
1	J. J. Patoliya; M. M. Desai	Face detection based ATM security system using embedded Linux platform	2017 2nd International Conference for Convergence in Technology (I2CT)	2017
1	E. N. Sandıkcı; Ç. E. Erdem; S. Ulukaya	A comparison of facial landmark detection methods	2018 26th Signal Processing and Communications Applications Conference (SIU)	2018
1	S. Ranganatha; Y. P. Gowramma	An integrated robust approach for fast face tracking in noisy Real-World videos with visual constraints	2017 International Conference on Advances in Computing, Communications and Informatics (ICACCI)	2017
1	D. Deb; N. Nain; A. K. Jain	Longitudinal Study of Child Face Recognition	2018 International Conference on Biometrics (ICB)	2018
1	S. Devi; P. K. Pateriya	Automatic system for recognition and identification of human objects	2017 International Conference on Intelligent Computing and Control Systems (ICICCS)	2017
1	U. B. Sai; K. Sivanagamani; B. Satish; M. R. Rao	Voice controlled Humanoid Robot with artificial vision	2017 International Conference on Trends in Electronics and Informatics (ICEI)	2017
1	N. Juneja; M. R. Kumar	Generating analytic insights on human behavior using image processing	2017 International Conference on Intelligent Computing and Control (I2C2)	2017
1	L. Stanciu; F. Blidariu	Emotional states recognition by interpreting facial features	2017 E-Health and Bioengineering Conference (EHB)	2017
1	D. Merget; T. Eckl; M. Schwoerer; P. Tiefenbacher; G. Rigoll	Capturing facial videos with Kinect 2.0: A multithreaded open source tool and database	2016 IEEE Winter Conference on Applications of Computer Vision (WACV)	2016
1	K. Gulzar; Jun Sang; O. Tariq	A cost effective method for automobile security based on detection and recognition of human face	2017 2nd International Conference on Image, Vision and Computing (ICIVC)	2017
1	P. Buitelaar; I. D. Wood; S. Negi; M. Arcan; J. P. McCrae; A. Abele; C. Robin; V. Andryushechkin; H. Ziad; H. Sagha; M. Schmitt; B. W. Schuller; J. F. Sánchez-Rada; C. A. Iglesias; C. Navarro; A. Giefer; N. Heise; V. Masucci; F. A. Danza; C. Caterino; P. Smrž; M. Hradiš; F. Povolný; M. Klimeš; P. Matějka; G. Tummarello	MixedEmotions: An Open-Source Toolbox for Multimodal Emotion Analysis	IEEE Transactions on Multimedia	2018
2	M. S. I. Sameem; T. Qasim; K. Bakhat	Real time recognition of human faces	2016 International Conference on Open Source Systems & Technologies (ICOSST)	2016
2	K. Koide; E. Menegatti; M. Carraro; M. Munaro; J. Miura	People tracking and re-identification by face recognition for RGB-D camera networks	2017 European Conference on Mobile Robots (ECMR)	2017
2	Jun-Cheng Chen, Rajeev Ranjan, Swami Sankaranarayanan, Amit Kumar, Ching-Hui Chen, Vishal M. Patel, Carlos D. Castillo, Rama Chellappa	Unconstrained Still/Video-Based Face Verification with Deep Convolutional Neural Networks	International Journal of Computer Vision	2018
1	T. Baltrušaitis; P. Robinson; L. Morency	OpenFace: An open source facial behavior analysis toolkit	2016 IEEE Winter Conference on Applications of Computer Vision (WACV)	2016
2	M. S. Sarma; Y. Srinivas; M. Abhiram; L. Ullala; M. S. Prasanthi; J. R. Rao	Insider Threat Detection with Face Recognition and KNN User Classification	2017 IEEE International Conference on Cloud Computing in Emerging Markets (CCEM)	2017
2	G. Geetha; M. Safa; C. Fancy; K. Chittal	3D face recognition using Hadoop	2017 International Conference on Energy, Communication, Data Analytics and Soft Computing (ICECDS)	2017
2	K. M. Rajesh; M. Naveenkumar	A robust method for face recognition and face emotion detection system using support vector machines	2016 International Conference on Electrical, Electronics, Communication, Computer and Optimization Techniques (ICEECOT)	2016
2	Min Luo; Yadong Luo; Hui Li; Xia Zhang; Yongkui Yang	Design and implementation of high resolution face image acquisition system under low illumination based on the open source computer vision library	2017 2nd International Conference on Image, Vision and Computing (ICIVC)	2017
1	BELLMAN, Christopher; MARTIN, Miguel Vargas; MACDONALD, Shane	(WKSP) On the Potential of Data Extraction by Detecting Unaware Facial Recognition with Brain-Computer Interfaces	2018 IEEE International Conference on Cognitive Computing (ICCC)	2018
1	POWERS, Nathaniel et al. Axaas: Case for acceleration as a service	Axaas: Case for acceleration as a service	Globecom Workshops (GC Wkshps), 2014	2014
1	CHINGOVSKA, Ivana; DOS ANJOS, Andre Rabello; MARCEL, Sebastien	Biometrics evaluation under spoofing attacks	IEEE Transactions on Information Forensics and Security	2014

1	SHI, Yanjie; CHEN, Guifen	Fast face detection method adapted for mobile platforms	Natural Computation (ICNC), 2014 10th International Conference on	2014
1	SU, Lin; LEVINE, Martin D.	High-stakes deception detection based on facial expressions	2014 22nd International Conference on Pattern Recognition (ICPR)	2014
1	IRUJO, Juan Arraiza et al	Multimedia analysis of video sources	Signal Processing and Multimedia Applications (SIGMAP), 2014 International Conference on	2014
2	AYAD, Marwa; TAHER, Mohamed; SALEM, Ashraf.	Real-time mobile cloud computing: A case study in face recognition	Advanced Information Networking and Applications Workshops (WAINA), 2014 28th International Conference on	2014
2	VALENCIA-REDROVÁN, David et al	SA 3 M: An interactive robot to provide support for the elderly	Power, Electronics and Computing (ROPEC), 2014 IEEE International Autumn Meeting on	2014
1	GEORGE, Treesa; POTTY, Sumi P.; JOSE, Sneha	Smile detection from still images using KNN algorithm	Control, Instrumentation, Communication and Computational Technologies (ICCICCT), 2014 International Conference on	2014
1	ŁŁOTKO, Paweł; SPECOGNA, Ruben	Topology preserving thinning of cell complexes	IEEE Transactions on Image Processing	2014
2	REN, Chuan-Xian et al	Transfer learning of structured representation for face recognition	IEEE Transactions on Image Processing	2014
1	RETAMINO, Eloy et al	Architecture and representation for handling dialogues in human-robot interactions	Signal and Information Processing Association Annual Summit and Conference (APSIPA), 2015 Asia-Pacific	2015
1	JOO, Jungseock; STEEN, Francis F.; ZHU, Song-Chun	Automated facial trait judgment and election outcome prediction: Social dimensions of face	Proceedings of the IEEE international conference on computer vision	2015
1	PAONE, J. et al	Baseline face detection, head pose estimation, and coarse direction detection for facial data in the SHRP2 naturalistic driving study	Intelligent Vehicles Symposium (IV), 2015 IEEE	2015
1	MAINA, Ciira Wa	Bioacoustic approaches to biodiversity monitoring and conservation in Kenya	IST-Africa Conference, 2015	2015
1	ZHANG, Weiwei et al	Driver yawning detection based on deep convolutional neural learning and robust nose tracking	Neural Networks (IJCNN), 2015 International Joint Conference on	2015
2	LK, Joshila Grace; RESHMI, K.	Face recognition in surveillance system	Innovations in Information, Embedded and Communication Systems (ICIIECS), 2015 International Conference on	2015
2	TULYAKOV, Sergey et al	Facecept3d: real time 3d face tracking and analysis	Proceedings of the IEEE International Conference on Computer Vision Workshops	2015
1	URICAR, Michal; FRANC, Vojtech; HLAVAC, Vaclav	Facial landmark tracking by tree-based deformable part model based detector	Proceedings of the IEEE International Conference on Computer Vision Workshops	2015
1	HUBER, Patrik et al	Fitting 3d morphable face models using local features	Image Processing (ICIP), 2015 IEEE International Conference on	2015
2	DUTTA, Abhishek et al	Impact of eye detection error on face recognition performance	IET biometrics	2015
1	BERLIN, Eugen et al	Low-power lessons from designing a wearable logger for long-term deployments	Sensors Applications Symposium (SAS), 2015 IEEE	2015
1	AYAD, Marwa; TAHER, Mohamed; SALEM, Ashraf	Mobile GPU Cloud Computing with real time application	Energy Aware Computing Systems & Applications (ICEAC), 2015 International Conference on	2015
2	JOON OH, Seong et al	Person recognition in personal photo collections	Proceedings of the IEEE International Conference on Computer Vision	2015
2	KLARE, Brendan F. et al	Pushing the frontiers of unconstrained face detection and recognition: IARPA Janus Benchmark A.	Proceedings of the IEEE conference on computer vision and pattern recognition	2015
1	WANG, Kun; ZHANG, Haifeng	Research on an improved algorithm of face detection based on skin color features and cascaded Ada Boost	Communication Technology (ICCT), 2015 IEEE 16th International Conference on	2015
1	GAYAKWAD, Shrutika S.; MOHOD, Prakash S	Revealing skull identity through a fusion of Viola-Jones and CCA	Advance Computing Conference (IACC), 2015 IEEE International	2015
2	CHENEY, Jordan et al	Unconstrained face detection: State of the art baseline and challenges	Biometrics (ICB), 2015 International Conference on	2015
1	XIA, Wen et al	A comprehensive study of the past, present, and future of data deduplication	Proceedings of the IEEE	2016
1	BADEJO, Joke A.; ATAYERO, Aderemi A.; IBIYEMI, Tunji S.	A robust preprocessing algorithm for iris segmentation from low contrast eye images	Future Technologies Conference (FTC)	2016
1	PRICE, Jim	California market designs for grid services to integrate renewable energy portfolios	Power and Energy Society General Meeting (PESGM), 2016	2016
1	MA, Jingwei; WANG, Gang; LIU, Xiaoguang	DedupeSwift: Object-Oriented Storage System Based on Data Deduplication	Trustcom/BigDataSE/I SPA, 2016 IEEE	2016
1	KORSHUNOV, Pavel; MARCEL, Sébastien	Joint operation of voice biometrics and presentation attack detection	Biometrics Theory, Applications and Systems (BTAS), 2016 IEEE 8th International Conference on	2016
1	MARASCO, Emanuela; WILD, Peter; CUKIC, Bojan	Robust and interoperable fingerprint spoof detection via convolutional neural networks	IEEE International Conference on Technologies for Homeland Security	2016
1	MARSTAL, Kasper et al	SimpleElastix: A user-friendly, multi-lingual library for medical image registration	Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops	2016
1	RUMINSKI, Jacek et al	The data exchange between smart glasses and healthcare information systems using the HL7 FHIR standar	Human System Interactions (HSI), 2016 9th International Conference on	2016
2	YU, Huapeng; LUO, Zhenghua; TANG, Yuanyan	Transfer Learning for Face Identification with Deep Face Model	Cloud Computing and Big Data (CCBD), 2016 7th International Conference on	2016
2	YUAN, Liping et al	A Convolutional Neural Network based on TensorFlow for Face Recognition	IEEE 2nd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC)	2017
1	PURUSHOTHAMAN, Sarath Kumar et al	Automation approach for cocos-2dx based multi-player card game for web and mobile	Computing and Communications Technologies (CCCT), 2017 2nd International Conference on	2017
1	SU, Bo-Hao et al	Friendly human-machine interaction on home care robot	Orange Technologies (ICOT), 2017 International Conference on	2017

1	GIRARD, Jeffrey M.; MCDUFF, Daniel	Historical heterogeneity predicts smiling: evidence from large-scale observational analyses	2017 12th IEEE International Conference on Automatic Face & Gesture Recognition (FG 2017)	2017
1	MILNE, Drew; RASMUSSEN, Jens	Marine Scotland open data network	OCEANS 2017-Aberdeen	2017
1	LAI, Kuan-Ling; CHOU, Huann-Ming	Open innovation: An analysis of the business model of digital cable television	Applied System Innovation (ICASI), 2017 International Conference on	2017
1	MEMON, Sheeraz et al	Tracker for sleepy drivers at the wheel	Signal Processing and Communication Systems (ICSPCS), 2017 11th International Conference on	2017
1	MACLEOD, Laura et al	Code Reviewing in the Trenches: Challenges and Best Practices	IEEE Software	2018
2	CAO, Bing et al	Data Augmentation-Based Joint Learning for Heterogeneous Face Recognition	IEEE transactions on neural networks and learning systems	2018
1	STEINMACHER, Igor; TREUDE, Christoph; GEROSA, Marco	Let me in: Guidelines for the Successful Onboarding of Newcomers to Open Source Projects	IEEE Software	2018
1	CAMPOMANES-ÁLVAREZ, Carmen et al	Modeling skull-face anatomical/morphological correspondence for craniofacial superimposition-based identification	IEEE Transactions on Information Forensics and Security	2018
1	BUSTO, Pau Panareda; IQBAL, Ahsan; GALL, Juergen	Open Set Domain Adaptation for Image and Action Recognition	IEEE transactions on pattern analysis and machine intelligence	2018
1	LI, Yu et al	Unsupervised Local Facial Attributes Transfer Using Dual Discriminative Adversarial Networks	2018 IEEE International Conference on Multimedia and Expo (ICME)	2018
2	DE MARSICO, Maria et al	FIRME: Face and iris recognition for mobile engagement	Image and Vision Computing, v. 32, n. 12, p. 1161-1172	2014
1	GHIDONI, Stefano et al	A distributed perception infrastructure for robot assisted living	Robotics and Autonomous Systems, v. 62, n. 9, p. 1316-1328	2014
2	RIDWAN, Mahmud et al	A navigational aid system for visually impaired using microsoft kinect	Proceedings of the International MultiConference of Engineers and Computer Scientists	2014
2	QI, Chang Xing; ZHAO, Lei; DONG, Qiao Ling	Design and Implementation of Safety Lock based on Face Recognition	Applied Mechanics and Materials	2014
1	BALANDIN, Sergey; ANDREEV, Sergey; KOUCHERYAVY, Yevgeni (Ed.)	Internet of Things, Smart Spaces, and Next Generation Networks and Systems	14th International Conference, NEW2AN 2014 and 7th Conference, ruSMART 2014, St. Petersburg, Russia	2014
2	SEDMIDUBSKY, Jan; MIC, Vladimir; ZEZULA, Pavel	Face image retrieval revisited	International Conference on Similarity Search and Applications	2015
1	HENRIQUES, João F. et al	High-speed tracking with kernelized correlation filters	IEEE Transactions on Pattern Analysis and Machine Intelligence	2015
1	OUANAN, Hamid; OUANAN, Mohammed; AKSASSE, Brahim	Implementation and optimization of face detection framework based on OpenCV library on mobile platforms using Davinci's technology	International Journal of Imaging and Robotics	2015
2	FU, Guohe; ZHANG, Xinyu	Rosbot: A low-cost autonomous social robot	Advanced Intelligent Mechatronics (AIM), 2015 IEEE International Conference on	2015
2	FRIČ, Vojtěch	Effectiveness of Camouflage Make-Up Patterns Against Face Detection Algorithms	International Conference Image Analysis and Recognition	2016
1	DOU, Tai H. et al	Fast simulated annealing and adaptive Monte Carlo sampling based parameter optimization for dense optical-flow deformable image registration of 4DCT lung anatomy	Medical Imaging 2016: Image-Guided Procedures, Robotic Interventions, and Modeling	2016
1	FERNANDES, Steven Lawrence; BALA, G. Josemin	ODROID XU4 based implementation of decision level fusion approach for matching computer generated sketches	Journal of computational science	2016
1	HUBER, Patrik et al	Real-time 3D face super-resolution from monocular in-the-wild videos	ACM SIGGRAPH 2016 Posters	2016
1	WANG, Kun; ZHANG, Haifeng	Research on an improved algorithm of face detection based on skin color features and cascaded Ada Boost	Communication Technology (ICCT), 2015 IEEE 16th International Conference on	2015
1	SUN, Wenyun; ZHAO, Haitao; JIN, Zhong	A facial expression recognition method based on ensemble of 3D convolutional neural networks	Neural Computing and Applications	2017
1	BADEJO, Joke A.; ATAYERO, Aderemi A.; IBIYEMI, Tunji S	A robust preprocessing algorithm for iris segmentation from low contrast eye images	Future Technologies Conference (FTC)	2016
1	BALBIN, Jessie R. et al	Cloud storage based mobile assessment facility for patients with post-traumatic stress disorder using integrated signal processing algorithm	Second International Workshop on Pattern Recognition	2017
1	RIGANELLI, Matteo et al	EmEx, a Tool for Automated Emotive Face Recognition Using Convolutional Neural Networks	International Conference on Computational Science and Its Applications	2017
1	PRIETO, Luis Antonio Beltran; OPLATKOVA, Zuzana Kominkova	Emotion Recognition in Video with OpenCV and Cognitive Services API: A Comparison	Annals of DAAAM & Proceedings	2018
1	PUTTEMANS, Steven; CAN, Ergun; GOEDEMÉ, Toon	Improving Open Source Face Detection by Combining an Adapted Cascade Classification Pipeline and Active Learning	Proceedings of VISAPP 2017	2017
2	EL FATIMI, Fatime Zahra et al	Board# 152: MAKER: MoDAR	2017 ASEE Annual Conference & Exposition	2017
1	KAINZ, Ondrej et al	On the Extraction of Anthropometric Parameters by Visual and Non-visual Means	eHealth 360°	2017
1	ALJOHANI, Mohammed; ALAM, Tanweer	Real time face detection in ad hoc network of android smart devices	Advances in Computational Intelligence	2017
1	ROKEM, Ariel et al	The visual white matter: The application of diffusion MRI and fiber tractography to vision science	Journal of vision	2017
1	NAGRANI, Arsha; CHUNG, Joon Son; ZISSERMAN, Andrew	Voxceleb: a large-scale speaker identification dataset	arXiv preprint arXiv:1706.08612	2017
2	WANG, Zhicheng et al	A simplified and efficient method for Facial Key points Detection	Proceedings of the 3rd International Conference on Intelligent Information Processing	2018
2	KRUTIKOVA, O.; SISOJEVS, A.	Face recognition method for cases of an insufficient training set, using 3D models of face that were created using two facial images	Optics, Photonics, and Digital Technologies for Imaging Applications V	2018
1	LEE, Chanjoo et al	Internet of Things: Technology to Enable the Elderly	2018 Second IEEE International Conference on Robotic Computing (IRC)	2018
1	TAN, Zheng-Hua et al	iSocioBot: A Multimodal Interactive Social Robot	International Journal of Social Robotics	2018

1	ABAWAJY, Jemal; CHOO, Kim-Kwang Raymond; ISLAM, Rafiqul (Ed.)	Optimization technology of CNN based on DSP	International Conference on Applications and Techniques in Cyber Security and Intelligence: Applications and Techniques in Cyber Security and Intelligence	2017
2	XIONG, Xiaoqian	Research and development of face recognition system based on ARM architecture	2018 International Conference on Intelligent Transportation, Big Data & Smart City (ICITBS)	2018
1	RAIF, Pawel; TKACZ, Ewaryst	The Face Tracking System for Rehabilitation Robotics Applications	Conference on Innovations in Biomedical Engineering	2017
1	WANG, Yuan-Kai; HUANG, Wen-Bin	A CUDA-enabled parallel algorithm for accelerating retinex	Journal of real-time image processing	2014
1	FUSEK, Radovan et al	An Improvement of Energy-Transfer Features Using DCT for Face Detection	International Conference on Image and Signal Processing	2014
1	FRANZ, Martin et al	CBMC-GC: an ANSI C compiler for secure two-party computations	International Conference on Compiler Construction	2014
2	SU, Xueping et al	Cross-modality based celebrity face naming for news image collections	Multimedia tools and applications	2014
1	VIEIRA, Tiago F. et al	Detecting siblings in image pairs	The Visual Computer	2014
1	ALCOVERRO, Marcel et al	Gesture control interface for immersive panoramic displays	Multimedia tools and applications	2014
1	MOSSI, Jose M. et al	Ground truth annotation of traffic video data	Multimedia Tools and Applications	2014
1	KRIG, Scott	Ground truth data, content, metrics, and analysis	Computer Vision Metrics	2016
1	KRIG, Scott	Interest point detector and feature descriptor survey	Computer vision metrics	2016
1	LEROY, Julien et al	KINterestTV-towards non-invasive measure of user interest while watching tv	International Summer Workshop on Multimodal Interfaces	2013
1	KRIG, Scott	Local Feature Design Concepts, Classification, and Learning	Computer Vision Metrics	2014
1	DOOMS, Simon et al	OMUS: an optimized multimedia service for the home environment	Multimedia tools and applications	2014
2	BREDIN, Hervé et al	Person instance graphs for mono-, cross-and multi-modal person recognition in multimedia data: application to speaker identification in TV broadcast	International journal of multimedia information retrieval	2014
1	DEMIRKUS, Meltem; CLARK, James J.; ARBEL, Tal	Robust semi-automatic head pose labeling for real-world face video sequences	Multimedia Tools and Applications	2014
1	HUISMAN, Gijs et al	Touching virtual agents: embodiment and mind	International Summer Workshop on Multimodal Interfaces	2013
1	SIZOV, Aleksandr; LEE, Kong Aik; KINNUNEN, Tomi	Unifying probabilistic linear discriminant analysis variants in biometric authentication	Joint IAPR International Workshops on Statistical Techniques in Pattern Recognition (SPR) and Structural and Syntactic Pattern Recognition (SSPR)	2014
2	RAMON, Manoel Carlos	Using OpenCV	Intel® Galileo and Intel® Galileo Gen 2	2014
1	KRIG, Scott	Vision Pipelines and Optimizations	Computer Vision Metrics	2016
1	RADEMAKER, Alexandre et al	A linked open data architecture for the historical archives of the Getulio Vargas Foundation	International Journal on Digital Libraries	2015
2	TAIMORI, Ali; BEHRAD, Alireza	A new deformable mesh model for face tracking using edge based features and novel sets of energy functions	Multimedia Tools and Applications	2015
1	KAUR, Amardeep; DATTA, Amitava	A novel algorithm for fast and scalable subspace clustering of high-dimensional data	Journal of Big Data	2015
1	ZHANG, Weishan et al	A video cloud platform combing online and offline cloud computing technologies	Personal and Ubiquitous Computing	2015
1	ANTÓN, Pablo et al	An immersive view approach by secure interactive multimedia proof-of-concept implementation	Multimedia Tools and Applications	2015
1	JUNG, Jong-Jin et al	An intuitive user interaction method using multi-sensors for pencil drawing filter of NPR rendering in mobile devices	Multimedia Tools and Applications	2015
1	LEE, Yong-Hwan; KIM, Youngseop	Efficient image retrieval using advanced SURF and DCD on mobile platform	Multimedia Tools and Applications	2015
1	FARAHAT, Ahmed K. et al	Greedy column subset selection for large-scale data sets	Knowledge and Information Systems	2015
1	KRAPIC, Luka; LENAC, Kristijan; LJUBIC, Sandi	Integrating Blink Click interaction into a head tracking system: implementation and usability issues	Universal Access in the Information Society	2015
1	KIM, Kyung-Joong; CHO, Sung-Bae	Meta-classifiers for high-dimensional, small sample classification for gene expression analysis	Pattern Analysis and Applications	2015
1	RAHMAN, Md Abdur	Multimedia environment toward analyzing and visualizing live kinematic data for children with hemiplegia	Multimedia Tools and Applications	2015
2	WHITELAM, Cameron; BOURLAI, Thirimachos	On designing an unconstrained tri-band pupil detection system for human identification	Machine Vision and Applications	2015
1	KIM, Min-Uk; YOON, Kyoungro	Performance evaluation of large-scale object recognition system using bag-of-visual words model	Multimedia Tools and Applications	2015
1	BARRENA, M. et al	Qatris iManager: a general purpose CBIR system	Machine Vision and Applications	2015
2	SILVA, Francisco Airton; MACIEL, Paulo; MATOS, Rubens	SmartRank: a smart scheduling tool for mobile cloud computing	The Journal of Supercomputing	2015
1	RAUTARAY, Siddharth S.; AGRAWAL, Anupam	Vision based hand gesture recognition for human computer interaction: a survey	Artificial Intelligence Review	2015
1	SINGH, Rahul Dev; MITTAL, Ajay; BHATIA, Rajesh K.	3D convolutional neural network for object recognition: a review	Multimedia Tools and Applications	2018
1	PARK, D. S.	Future computing with IoT and cloud computing	The Journal of Supercomputing	2018
1	ZHANG, Jie et al	Locality-constrained framework for face alignment	Frontiers of Computer Science	2018
2	DONON, Y.	Hybrid face recognition solution for security	IV International Conference on "Information Technology and Nanotechnology"	2018
2	MISRA, Dharitri; GILL, Michael J.	FaceMatch: A System for Dynamic Search and Retrieval of Faces	Archiving Conference	2018
1	ZHOU, Fei Yan; JIN, L. P.; DONG, Jun	Review of convolutional neural network	Chinese Journal of Computers	2017
2	WANDZIK, Lukasz et al	CNNs under attack: on the vulnerability of deep neural networks based face recognition to image morphing	International Workshop on Digital Watermarking	2017
1	HOU, Y.; YANG, L.	The application of computer vision and machine learning technology in 3D human animation	International Journal of Simulation: Systems, Science and Technology	2016

2	RAJKUMAR, S.; PRAKASH, J.	Automated attendance using raspberry Pi	International Journal of Pharmacy and Technology	2016
2	LEONARD, Kevin R.	Assessment of Facial Recognition System Performance in Realistic Operating Environments	Face Recognition Across the Imaging Spectrum	2016

ANEXO A – Autorização de uso de imagens de passaportes



SERVIÇO PÚBLICO FEDERAL
MSP - POLÍCIA FEDERAL
SETOR DE ANÁLISE DE DADOS DE INTELIGÊNCIA POLICIAL - SADIP/CGPI/DIREX/PF

Assunto: **Extração de dados**

Destino: **CGPI/DIREX**

Processo: **08490.003256/2018-43**

Interessado: **GUILHERME BIRCKAN**

1. Ciente:

2. Trata-se de solicitação de aluno regular do Mestrado Acadêmico em Ciência da Informação para acessar a massa de dados de imagens de documentos de cidadãos, viabilizado com o acesso a cópia de bancos de dados do sistema de emissão de passaporte (SINPA).

3. Este SADIP/CGPI já se manifestou no despacho SEI nº 6794835: "*Este SADIP/CGPI não vê óbice ao acesso pleiteado, ainda mais porque o projeto de pesquisa aponta para atendimento de questões de interesse da Polícia Federal, como a inovação tecnológica e desenvolvimento de ferramentas para utilização do órgão em suas atribuições. Saliento, apenas, o atendimento à preservação e a segurança da informação disponibilizada, conforme já exposto*", sendo que mantém a manifestação já externada.

4. Retorne-se ao CGPI/DIREX, para conhecimento.

5. Encerro o presente neste setor.



Documento assinado eletronicamente por **EDUARDO MARCIO SANTOS GALDINO DA SILVA, Chefe de Setor**, em 15/08/2018, às 19:30, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.dpf.gov.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **7858911** e o código CRC **C147B8E3**.