

# LEVANTAMENTO DA LITERATURA DE RECONHECIMENTO FACIAL

Ana Paula G. Castro<sup>1</sup>, Bruno M. Acraini<sup>1</sup>, Brenda S. A Silva<sup>1</sup>, Leandro C.  
Fernandes<sup>1</sup>

<sup>1</sup>Faculdade de Computação e Informática – Universidade Presbiteriana Mackenzie  
(Mackenzie)

Brasil, SP, São Paulo, Rua da Consolação, 930 - Prédio 31, 1º andar

{anapj11@gmail.com, brunominiaci@outlook.com,  
brendasantos547@gmail.com}, leandro.fernandes@mackenzie.br

**Resumo.** *É nítido que para o ser humano é muito mais fácil reconhecer o rosto de pessoas conforme algumas determinadas características físicas, pois é habilidade natural. No entanto, conseguir implementar esta habilidade e a capacidade de reconhecimento facial em máquinas é uma tarefa complexa. Desta forma, este artigo tem como objetivo fazer um levantamento literário sobre os métodos e técnicas computacionais de reconhecimento facial, visando compreender suas diversas formas de implementação.*

**Palavras-chave:** *Tecnologia, Reconhecimento, Facial, Inteligência Artificial, Processamento de Imagem, Rosto, Faces, Machine Learning, Redes Neurais e Deep Learning.*

**Abstract.** *It is clear that for human beings it is much easier to recognize people's faces according to certain physical characteristics, as it is a natural ability. However, being able to implement this skill and the ability of facial recognition in machines is a complex task. In this way, this article aims to make a literary survey on the computational methods and techniques of facial recognition, aiming to understand its various forms of implementation.*

**Keywords:** *Tecnologia, Reconhecimento, Facial, Inteligência Artificial, Processamento de Imagem, Rosto, Faces, Machine Learning, Redes Neurais e Deep Learning.*

## 1. INTRODUÇÃO

O cérebro humano é capaz de reconhecer diversos tipos de padrões e um exemplo disso é reconhecer rostos com facilidade. Em sua rotina diária, uma pessoa consegue identificar diversas características e diferenciá-los sem grande esforço, através dos traços do rosto, nariz, boca ou até mesmo corte de cabelo. No entanto, ao contrário do cérebro humano, os computadores não possuem essa facilidade para realizar um reconhecimento facial preciso, então é necessário um processamento feito através de algum software.

Apesar de ser um tema em ascensão na atualidade, o desenvolvimento começou aproximadamente na década de 1960. Uma equipe liderada por Woodrow W Bledsoe realizou um experimento entre 1964 e 1966 com o foco de verificar se computadores conseguiam reconhecer rostos humanos. Através de um scanner rudimentar, a equipe tentou mapear a localização de características das pessoas, como linha do cabelo, olhos e nariz. Infelizmente, o experimento não teve um resultado positivo, pois a tecnologia da época não foi suficientemente eficaz para concluir sua pesquisa, dificultado pela iluminação, intensidade, expressão facial e envelhecimento. No entanto, apenas em 1991 que o reconhecimento facial de rostos tornou-se automatizado, quando Turk e Pentland expandiram o algoritmo Eigenface, desenvolvido em 1988 por Sirovich e Kirby.

Para um computador, a capacidade de reconhecer faces é complexa, porém, com o avanço tecnológico conseguem reconhecer faces com mais eficácia, podendo assim ser utilizado em diversas áreas solucionando uma variedade de problemas. Por exemplo, verificação de identidade, processamento de imagens, classificação de imagens, segurança de dados e detecção de fraude. Com isso, foram desenvolvidos modelos e técnicas de reconhecimento facial a fim de aprimorar a habilidade de reconhecer rostos, por exemplo o aprendizado de máquina, um conjunto de técnicas para construir sistemas capazes de adquirir conhecimento automaticamente. Outra técnica utilizada são as Redes Neurais Artificiais, primeiramente desenvolvida por Frank Rosenblatt, chamado de *perceptron*, constituídas por neurônios artificiais que trocam informações entre si.

### 1.1 HIPÓTESE

Deep Learning é a tecnologia utilizada em inteligência artificial mais eficaz para reconhecimento facial no mercado atual.

## **1.2 OBJETIVO**

Este artigo tem como objetivo o levantamento da literatura a respeito de principais técnicas mais eficazes na atualidade, seus métodos de implementação e fazer uma síntese sobre o comportamento dessas técnicas, pontuando as vantagens ou desvantagens.

## **1.3 MOTIVAÇÃO**

O emprego do reconhecimento facial tem se mostrado cada vez mais presente nos sistemas, inclusive nas mais diversas situações e domínios, ganhando atenção devido às expectativas associadas à identificação unívoca que essa técnica traz. Tornou-se mais popular com o objetivo de autenticação para proteção de dados, a fim de evitar violações ao direito à privacidade. É de extrema importância uma implementação de alta qualidade, onde através de uma câmera, imagem ou vídeo consiga identificar uma pessoa através do rosto. No entanto, a boa conduta e armazenamento desses dados devem ser tratados com seriedade e segurança. A partir desse entendimento, gerou-se uma curiosidade para compreender como funciona a aplicação desta tecnologia e como funciona os seus métodos.

## **2. REFERENCIAL TEÓRICO**

Com base no contexto apresentado, esta seção traz um referencial teórico necessário para compreensão das técnicas usadas no reconhecimento facial, explicando suas principais características e aplicabilidades.

### **2.1 INTELIGÊNCIA ARTIFICIAL**

A inteligência artificial é uma área que vem ganhando bastante notoriedade e está tendo um visível crescimento. Os sistemas de inteligência artificial incluem pessoas, procedimentos, hardwares, softwares, dados e conhecimentos necessários para realizar um desenvolvimento em sistemas computacionais e em máquinas que demonstram fatores de inteligência. Um dos campos de IA que está em plena ascensão está relacionado com sistemas de visão, ou seja, nestes sistemas são incluídos hardwares e softwares que possibilitam que os computadores realizem a captação, armazenamento e a manipulação de imagens. Estes sistemas de visão computacional também se destacam em identificar pessoas com base em traços faciais.

## 2.2 PROCESSAMENTO DE IMAGENS

O processamento de imagens é certamente uma área que está constantemente crescendo. Primeiramente é curioso dizer que a disciplina de processamento de imagens se originou do processamento de sinais. Os sinais, como as imagens, são basicamente um suporte físico que carrega internamente uma determinada informação. Podendo estar relacionada com uma medida (está relacionado com algum fenômeno físico) ou a um nível cognitivo (está relacionado a algum conhecimento). Logo, processar uma imagem equivale a transformá-la sucessivamente como um objeto de extrair mais facilmente a informação que está presente nela mesma. Sendo assim, o processamento de imagens parte da imagem (de uma informação inicial que geralmente é captada através de uma câmera) ou até mesmo de uma sequência de imagens para obtermos a “Informação”.

## 2.3 APRENDIZADO DE MÁQUINA (*MACHINE LEARNING*)

A Inteligência Artificial é uma das ciências mais recentes, tendo início após a Segunda Guerra Mundial e, atualmente, abrange uma enorme variedade de subcampos, desde áreas de uso geral, como aprendizado e percepção, até tarefas específicas como jogos de xadrez, demonstração de teoremas matemáticos, criação de poesia e diagnóstico de doenças. A IA sistematiza e automatiza tarefas intelectuais e, portanto, é potencialmente relevante para qualquer esfera da atividade intelectual humana. (GOMES, D. dos S, 2010, p. 234-246).

Machine Learning (ou aprendizado de máquina) é uma tecnologia da área de estudo da Inteligência Artificial (IA), que se aprimoram de forma automática de acordo com as respostas por meio de uma experiência, podendo ser através de imagens e ou modelos matemáticos. Pensando no desenvolvimento de um sistema de aprendizado de máquina, o método usado para a criação é através da indução, onde as hipóteses são desenvolvidas a partir de dados, podendo ser corretos ou incorretos, com isso, o objetivo final deste sistema é elaborar as próprias regras ou perguntas. As técnicas de aprendizado de máquina se agrupam, essencialmente, nas seguintes categorias:

- **Aprendizado supervisionado:** O aprendizado de máquina supervisionado é aquele que ensina a máquina através de algoritmos o que é uma face e por meio disso consegue reconhecer novas faces através de fórmulas desenvolvidas.
- **Aprendizado não-supervisionado:** O aprendizado não supervisionado é aquele que possui um conjunto de dados e a máquina tem como objetivo localizar imagens semelhantes, sendo assim, não tendo em mente como será a saída, ou

seja, se irá conseguir localizar as imagens que possuem um mesmo tipo de padrão, ou se irão ao menos tentar ou até mesmo dar erro. A máquina tenta realizar uma ação, dependendo de como será a ação, isto é, se for uma ação classificada errada, a mesma realiza uma nova tentativa, até encontrar a melhor solução para o problema proposto, lembrando que todas essas ações são realizadas de fórmulas matemáticas.

## **2.4 DEEP LEARNING**

Deep Learning é, atualmente, a principal tecnologia utilizada em sistemas de inteligência artificial. São redes profundas que tentam simular em máquinas o funcionamento do cérebro humano. Esta técnica está crescendo constantemente devido ao volume de dados que vêm sendo gerados todos os dias. Estes dados estão se multiplicando anualmente além do avanço estar relacionado com a melhoria das máquinas que estão sendo usadas para realizar análise destas técnicas. A base da deep learning está ligada com as redes neurais convolucionais (CNNs) realçando no reconhecimento de padrões, e atualmente é a principal tecnologia para carros autônomos, reconhecimento facial, transição de fala entre outras aplicações.

## **2.5 REDES NEURAIAS ARTIFICIAIS**

Redes neurais artificiais (RNAs) referem-se a sistemas computacionais que possuem um funcionamento baseado em um cérebro humano. Como o seu nome mesmo indica, são redes computacionais que tentam simular o processo de decisão nas redes de células nervosas do sistema nervoso central biológico. Os neurônios biológicos possuem o objetivo de disparar sinais elétricos, responsáveis pelo processamento do cérebro humano.

As redes contribuíram muito para o desenvolvimento de sistemas de reconhecimento facial e classificações de padrões. A partir disso, o primeiro neurônio artificial, base do funcionamento de redes neurais foi o *perceptron*, tendo como objetivo gerar saídas mais rígidas, desenvolvido nas décadas de 1950 e 1960 por Frank Rosenblatt, considerado um dos modelos mais simples. No entanto, na atualidade o modelo de neurônio artificial que está sendo mais utilizado é o *sigmoide neuron*, que diferente do *perceptron*, gera saídas sigmoidais. Esta constatação pode ser visualizada na figura 1.

### **2.5.1 REDES NEURAIAS CONVOLUCIONAIS (CNN)**

As redes neurais convolucionais são bastante adaptáveis para a classificação de imagens, pois, ao contrário das arquiteturas mostradas anteriormente, as CNNs utilizam-se da estrutura espacial da imagem. O nome Rede Neural Convolucional se deu origem através do fato da rede aplicar uma operação matemática cujo o seu nome é convolução, sendo um tipo especializado de operação linear. Nas redes neurais convolucionais, os neurônios da primeira camada da rede recebem os píxeis da imagem de entrada, um pixel por neurônio, porém esses neurônios não são conectados diretamente na camada seguinte, ao invés disso, é criado um campo receptivo local, que nada mais é que o agrupamento de uma região dos neurônios da primeira camada. O agrupamento pode possuir diversos tamanhos, por exemplo, 5x5 neurônios, o que corresponde a 25 neurônios da camada de entrada. Cada um dos neurônios agrupados é conectado a um neurônio da segunda camada utilizando os mesmos pesos e vieses, que são conhecidos como pesos e vieses compartilhados, ou kernel, ou filtro.

A rede convolucional obtém a imagem com extratos separados de cores, sendo elas vermelho, azul e verde, o famoso sistema “RGB”, que são medidos pela quantidade de pixels, onde a profundidade é delimitada em três camadas, podendo ser chamadas de canais. Em uma CNN são realizadas diversas operações matemáticas, onde acontecem os filtros, como objetivo obter informações das imagens e no final como saída uma probabilidade para identificar se a imagem pode ser um animal, pessoa ou objeto por exemplo.

### **2.6 DEEP LEARNING**

Deep Learning é, atualmente, a principal tecnologia utilizada em sistemas de inteligência artificial. São redes profundas que tentam simular em máquinas o funcionamento do cérebro humano. Esta técnica está crescendo constantemente devido ao volume de dados que vêm sendo gerados todos os dias. Estes dados estão se multiplicando anualmente além do avanço estar relacionado com a melhoria das máquinas que estão sendo usadas para realizar análise destas técnicas. A base da deep learning está ligada com as redes neurais convolucionais (CNNs) realçando no reconhecimento de padrões, e atualmente é a principal tecnologia para carros autônomos, reconhecimento facial, transição de fala entre outras aplicações.

## 2.7 EIGENFACES

O método Eigenfaces é um conjunto de vetores, que não depende das formas geométricas do rosto, utilizados em problemas relacionados à visão dos computadores. Seu funcionamento é similar ao de análise de componentes principais (PCA).

Estes autovetores são derivados de uma matriz de covariância de uma distribuição de probabilidade de um vetor espacial. Para obtermos um conjunto de eigenfaces é necessário possuir um grande agrupamento de imagens de faces humanas, sendo que elas devem ter a mesma iluminação e alinhadas seguindo as linhas dos olhos e da boca. Sendo assim, as autofaces podem ser extraídas por meio de uma ferramenta matemática cujo o seu nome é análise de componentes principais (PCA).

Depois de encontrar os autovetores, as imagens de faces são projetadas em um espaço de características “espaço de faces” que melhor representa a variação entre faces conhecidas. Esse espaço é definido pelas Eigenfaces, que são os autovetores do conjunto de faces. O reconhecimento de uma face é realizado pela sua projeção no subespaço gerado pelas Eigenfaces e então pela comparação da posição obtida com a posição de indivíduos conhecidos.

No método de Eigenfaces, as imagens podem ser codificadas linearmente usando uma pequena amostra. Sendo assim, Eigen Pictures é o nome dado em relação a um conjunto de vetores-base ótimos, pois são apenas Eigenvectors de matrizes de covariância calculadas a partir das imagens no conjunto de treino. Vale ressaltar que um critério crucial nesse método está relacionado com a iluminação, ou seja, uma vez que um eigenvectors se baseia nas diferentes variações dos rostos, assim como nas variações de luminosidade. Esta constatação pode ser visualizada na figura 1.



Figura 1 – Representação de uma imagem após o Eigenfaces (TRAN, 2008).

## 2.8 FISHERFACES

Na linha de pesquisa que utiliza a abordagem holística, o algoritmo de fisherfaces pode ser definido como uma versão mais atualizada do algoritmo de eigenfaces, pois é por meio dele que podemos extrair componentes principais que nos ajudam a diferenciar uma pessoa da outra. Este método está relacionado com uma matriz de transformação de uma classe específica, para que não haja uma captura de iluminação. Por meio disso, o desempenho do fisherfaces possui uma dependência direta com os dados de entrada. Sendo assim, se as fotos forem tiradas com uma qualidade muito boa de iluminação e os testes forem utilizados com má iluminação logo, o método se torna vulnerável e propício a encontrar erros. Para resolver esse problema podem ser utilizados métodos estatísticos de redução de dimensionalidade, por exemplo análise de componentes principais (PCA).

Assim como mencionado anteriormente, os Eigenfaces são similares às fisherfaces, entretanto, as mesmas podem ser visualizadas como imagens de características, isto é, onde as características das fisherfaces são variações de aparência presentes nas imagens de cada pessoa, sendo elas, variações de iluminação, poses e expressões faciais. Logo, assim como as imagens em um espaço de dados possuem um valor atribuído para cada atributo, os vetores e características possuem um valor para cada. Sendo assim, podemos concluir que quanto mais as pessoas forem diferentes, mais distantes suas projeções estarão e quanto mais parecidas forem as imagens de um indivíduo, mais próximas deverão estar suas projeções. De acordo com Bissi (2018), o algoritmo Fisherface é composto por 8 etapas, sendo elas:

1. Cálculo da face média por classe: A face média por classe é o resultado da soma pixel a pixel de todas as imagens de uma mesma classe do conjunto de treinamento dividido pelo total de imagens da classe.
2. Cálculo de face média geral: A face média é o resultado da soma pixel a pixel de todas as imagens do conjunto de treinamento dividido pelo total de imagens.
3. Transformação das imagens em vetores: A transformação de uma imagem em um vetor consiste em concatenar as linhas da imagem, unindo o último pixel de cada linha com o primeiro pixel da linha seguinte, formando um vetor de pixels.
4. Construção da matriz de dispersão intra-classe: A matriz de dispersão intraclasse calcula o quanto os dados estão dispersos dentro da própria classe, isto é, o quanto as imagens de um mesmo indivíduo diferem umas das outras.



5. Construção da matriz de dispersão inter-classe: A matriz de dispersão interclasse  $S_b$  calcula o quanto os dados estão dispersos entre as classes, isto é, o quanto as imagens de indivíduos distintos diferem umas das outras.
6. Cálculo das fisherfaces: As Fisherfaces do LDA e seus valores associados são, respectivamente, os autovetores e autovalores.
7. Cálculo dos vetores de características: As imagens de face são representadas pela soma ponderada das Fisherfaces. Os pesos dessa combinação foram os vetores de características das imagens de face. Para calcular o peso de cada Fisherface na representação de uma imagem de face, multiplica-se a imagem de face, subtraída da média, por cada uma das Fisherfaces.
8. Cálculo da Similaridade: O reconhecimento pode ser realizado por meio do uso de um classificador ou de uma métrica de similaridade. Uma das métricas de similaridade mais comum é a distância euclidiana.

### 3. MÉTODO DE PESQUISA

A estratégia adotada para a condução deste trabalho investigativo consistiu na pesquisa e levantamento de publicações científicas, com escopo temporal e temático definidos, segundo os objetivos a que se pretende. Com esta abordagem, desenvolvemos um SmartArt para ter eficiência e precisão ao definir os critérios de estudo. Esta constatação pode ser visualizada na figura 2.



Figura 2 – Smart Art das Etapas de Estudo (Fonte: Elaboração Própria).

### **3.1 DEFINIÇÃO DE CRITÉRIOS**

Para conseguir uma base eficaz de informação, foram definidos critérios para nossa pesquisa. Com isso, utilizamos *palavras-chaves* para identificar artigos que estejam de acordo com nossas intenções na pesquisa, sendo elas: Tecnologia, Reconhecimento Facial, Inteligência Artificial, Processamento de Imagem, Rosto, Faces, Machine Learning, Redes Neurais e Deep Learning.

Procuramos artigos científicos nos idiomas em português e inglês, pelo fácil acesso ao entendimento e absorção de conteúdo.

Também levamos em consideração o ano de publicação do artigo, onde apenas selecionamos e incluímos na nossa base de pesquisa, artigos publicados nos últimos 8 anos de produção, pois assim conseguimos informações atuais evitando estudar métodos e técnicas obsoletas que não agregariam na pesquisa.

### **3.2 SELEÇÃO DOS ESTUDOS**

Consultando as principais bases (IEEE, ACM, Elsevier e também utilizando o Google Scholar) de pesquisa de artigos científicos, obtendo um número extenso de artigos selecionados, onde foram avaliados através dos critérios acima e metodologia apropriada com o tema.

O montante foi triado e categorizado por propósito (aplicação) e técnica (ML, Proc.Img) com base na análise da seção descritiva resumida do artigo (abstract). Isso permitirá, além de uma classificação, identificar os conteúdos de maior interesse e reduzir a base de artigos a serem trabalhados com mais profundidade.

Por fim, foi feito um levantamento das técnicas, seus desempenhos, fragilidades e pontos fortes; correlacionar o tipo de aplicação com a eficiência da técnica empregada.

## **4. RESULTADOS DO ESTUDO**

Neste trabalho foram obtidos 67 artigos científicos para alcançar o objetivo principal do projeto. Ao ler o texto por completo ou apenas o resumo (abstract) de cada artigo científico identificado para a revisão da literatura, esta constatação pode ser visualizada na tabela 2, observamos que alguns não estavam de acordo com a nossa finalidade no projeto, pois abordavam sobre técnicas obsoletas na atualidade, não agregando positivamente no levantamento das tecnologias atuais.

A partir disso, filtramos e retiramos esses artigos da nossa base de dados, categorizando em temas, deixando assim nossa pesquisa mais organizada, evitando a revisão de técnicas e conteúdos não produtivos na atualidade do projeto. Esta constatação pode ser visualizada na tabela 1.

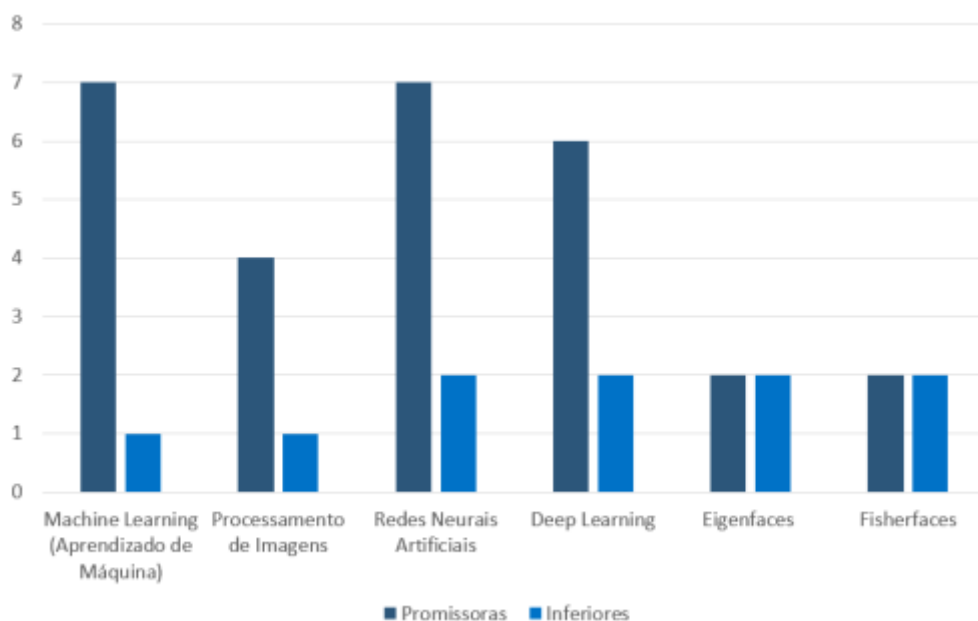
Nome das Categorias	Quantidade de Artigos Científicos Iniciais	Artigos Científicos Descartados	Quantidade de Artigos utilizados
Machine Learning	10	2	8
Processamento de Imagens	6	1	5
Redes Neurais Artificiais	13	4	9
Deep Learning	11	3	8
Inteligência Artificial	12	2	10
Eigenfaces	5	1	4
Fisherfaces	4	0	4
Reconhecimento Facial	6	1	5

**Tabela 1 – Categorização, Seleção e Descarte de Artigos.**

Nome das Categorias	Artigos Científicos lidos na totalidade	Artigos Científicos lidos apenas o resumo
Machine Learning	6	4
Processamento de Imagens	4	2
Redes Neurais Artificiais	8	5
Deep Learning	7	4
Inteligência Artificial	8	2
Eigenfaces	3	1
Fisherfaces	3	1
Reconhecimento Facial	5	1

**Tabela 2 – Artigos lidos na totalidade ou apenas resumo.**

Após as leituras completas dos artigos, categorizamos as técnicas como promissoras e inferiores em termos de desempenho e resultados positivos abordado no conteúdo dos artigos. Esta constatação pode ser visualizada no gráfico 1.



**Gráfico 1 – Técnicas Promissoras e Inferiores.**

A partir disso, sintetizamos sobre cada conteúdo separado de acordo com o material levantado através da aplicação dos métodos de pesquisa. Apontando fragilidades e pontos fortes das técnicas e seus meios de implementação. Com isso, foi possível observar as dificuldades que as tecnologias enfrentam para ter uma eficácia.

Existem fatores externos que tornam-se obstáculos para garantir o bom proveito da ferramenta, por exemplo a iluminação, prejudicando o reconhecimento facial sendo ele através de uma imagem ou câmera de vídeo live. Também podendo ser objetos, por exemplo máscaras, pensando na recente pandemia do covid-19, onde tornou-se uma grande dificuldade para as tecnologias de reconhecimento facial.

Através do conteúdo estudado, percebemos que existem diversos métodos e técnicas para auxiliar nesses fatores externos que complicam sua funcionalidade. Por exemplo, a capacidade do algoritmo de Fisherfaces em identificar faces é uma realidade, porém enfrenta dificuldade no processamento de imagens, com isso foram desenvolvidos métodos para melhorar sua eficácia, através da aplicação de filtros Bilateral, Gaussiano e Equalização de Histograma.

A capacidade do algoritmo de Fisherfaces em identificar rostos é uma realidade, porem quando estes estão em imagens onde as condições não cooperam, está se torna uma tarefa complexa para o algoritmo. Sob a hipótese de que alterar estas imagens, de forma a realçar as informações mais importantes, pode melhorar o processo de reconhecimento, foram selecionadas soluções com ferramentas de

código aberto, renomadas na área de processamento de imagens. [GUIMARÃES, 2015].

Técnicas de Deep Learning tem conseguido atingir resultados estatisticamente impressionantes em particular, como demonstrado, pelo uso de múltiplas camadas. Entretanto, existem limitações no uso de redes neurais profundas pois essas são basicamente uma forma de aprender uma série de transformações a serem aplicadas ao vetor de entrada. [CHOLLET, 2017]

## **5. CONCLUSÃO**

Este trabalho tem como objetivo principal realizar um levantamento da literatura das técnicas atuais aplicadas na área de reconhecimento facial e suas formas de implementação. Tais técnicas são utilizadas em diversas situações do dia a dia, com o objetivo de facilitar e aprimorar serviços que necessitam do reconhecimento facial para a sua funcionalidade.

Com o decorrer do tempo e o avanço tecnológico, as técnicas de reconhecimento facial foram aprimoradas com o uso de tecnologias como a Machine Learning, com esse tipo de tecnologia foram comprovadas em casos de estudos de processamento de imagens que é possível reconhecer um rosto mesmo que ele sofra modificações ao longo do tempo.

Os objetivos do trabalho foram alcançados utilizando a aplicação das estratégias de pesquisa, onde observamos diversos métodos de implementação e soluções para as técnicas abordadas no projeto. A pesquisa reuniu informações sobre as áreas de Redes Neurais, Machine Learning, Deep Learning, Processamento de imagem, Fisherfaces e Eigenfaces. Com as informações coletadas foi possível observar que, apesar das dificuldades de se obter um sistema de reconhecimento facial confiável, é possível alcançar bons resultados. Mesmo com fatores externos e internos, a taxa de acerto dos métodos estudados está aproximadamente em 80%, garantindo um resultado positivo e com baixa taxa de erros.

Por fim, levando em consideração os trabalhos relacionados, acreditamos que o Deep Learning é a técnica mais eficiente no mercado, atualmente é a tecnologia mais utilizada em reconhecimento facial, devido a sua alta taxa de acerto. Pois o mesmo trouxe um novo horizonte de possíveis soluções que outras técnicas tem dificuldades, proporcionando grandes avanços na área de reconhecimento facial.

## 6. REFERÊNCIAS

ABREU, V. R. G. Reconhecimento Facial - Comparação do Uso de Descritores Geométricos Heurísticos e Aprendizagem Profunda. **Universidade D Coimbra**. 2021. Disponível em:

<[https://estudogeral.uc.pt/bitstream/10316/94339/1/Disserta%C3%A7%C3%A3o\\_VivianaAbreu.pdf](https://estudogeral.uc.pt/bitstream/10316/94339/1/Disserta%C3%A7%C3%A3o_VivianaAbreu.pdf)>

BISSI, Thelry David. Reconhecimento facial com os algoritmos eigenfaces e fisherfaces. 2018. 41 f. Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) – **Universidade Federal de Uberlândia**, Uberlândia, 2018. Disponível em:

<<http://repositorio.ufu.br/bitstream/123456789/22158/3/ReconhecimentoFacialAlgotimos.pdf>>

COELHO, Matheus. Inteligência Artificial E Deep Learning. **Laboratório iMobilis Computação Móvel**. 2019. Disponível em:

<<http://www2.decom.ufop.br/imobilis/category/blog/>>

CHAVES, Rodrigo Reuse. REDES NEURAIIS DEEP LEARNING APLICADAS AO RECONHECIMENTO FACIAL. **UCS**. 2018. Disponível em: <<https://repositorio.ucs.br/xmlui/bitstream/handle/11338/4771/TCC%20Rodrigo%20Reuse%20Chaves.pdf?sequence=1&isAllowed=y>>

Donato, H. and Donato, M. 2019. Stages for Undertaking a Systematic Review. Acta Med Port, 2019.

FRANCOIS. Chollet. Deep Learning with Python. Manning, 2017.

FRANCISCO, Marcos Antonio; ROZAR, Jéssyca Luiz. RECONHECIMENTO FACIAL COM TÉCNICAS DE MACHINE LEARNING. **UNISUL**. 2020.

Disponível em:

<<https://repositorio.animaeducacao.com.br/bitstream/ANIMA/11061/5/TCC-RECONHECIMENTO%20FACIAL%20COM%20T%c3%89CNICAS%20DE%20MACHINE%20LEARNING.pdf>>

GOMES, D. dos S. Inteligência Artificial: conceitos e aplicações. **Olhar Científico**. v1, n. 2, p. 234-246, 2010. Citado na página 3.

ITTNER, Matheus Henrique. Utilização de reconhecimento facial para auxílio de deficientes visuais. **UFSM**. 2021. Disponível em: <<https://repositorio.ufsm.br/handle/1/22649>>

JESUS, Leone; GUIMARÃES, Deivite; SAPUCAIA, Flávio; PIMENTEL, Fagner; SOUZA, J. R. de S; SIMÕES, Marco A. C; FRIAS, Diego. Análise de Métodos de Processamento de Imagens para Reconhecimento Facial utilizando Fisherfaces em Imagens sob Condições Desfavoráveis. **UNEB**. 2015. Disponível em: <[http://www.acso.uneb.br/bahiar/uploads/BibFiles/ERBASE\\_WTICG\\_2015\\_Home\\_ReconhecimentoFacial.pdf](http://www.acso.uneb.br/bahiar/uploads/BibFiles/ERBASE_WTICG_2015_Home_ReconhecimentoFacial.pdf)>

MAIA, Hugo Leite Florenço. Detecção e reconhecimento facial por meio de aprendizado de máquina. 2016. 50 f., il. Monografia (Bacharelado em Engenharia de Redes de Comunicação)—**Universidade de Brasília**, Brasília, 2016. Disponível em: <<https://bdm.unb.br/handle/10483/15247>>

MINATTO, Danielle. CORAL, Sergio. GARCIA, Merisandra. Análise de Características em Redes Neurais Artificiais Aplicadas em Visão Computacional com Ênfase em Reconhecimento Facial. UNESC.

NEVES, V. R. C. Reconhecimento Facial: Uma Breve Introdução. **Universidade Federal Fluminense - Instituto de Computação**. 2020. Disponível em: <[http://www.midiacom.uff.br/debora/images/disciplinas/2020-1/trabalhos/Face\\_Recognition.pdf](http://www.midiacom.uff.br/debora/images/disciplinas/2020-1/trabalhos/Face_Recognition.pdf)>

OKABE, Rogerio Kazuhiro; CARRO, Silvio Antonio. RECONHECIMENTO FACIAL EM IMAGENS CAPTURADAS POR CÂMERAS DIGITAIS DE REDE. **UNOESTE**. 2014. Disponível em: <<https://revistas.unoeste.br/index.php/ce/article/view/1307/1425>>

SILVA, A. B. N. RECONHECIMENTO FACIAL UTILIZANDO EIGENFACES. UFRJ. 2013. Disponível em: <<https://www.lcg.ufrj.br/~marroquim/courses/cos756/trabalhos/2013/abel-nascimento/abel-nascimento-report.pdf>>

SILVA, A. L. REDUÇÃO DE CARACTERÍSTICAS PARA CLASSIFICAÇÃO DE IMAGENS DE FACES. **UFERSA - UERN**. 2016. Disponível em: <<https://ppgcc.ufersa.edu.br/wp-content/uploads/sites/42/2014/09/REDU%C3%87%C3%83O-DE-CARACTER%C3%8DSTICAS-PARA-CLASSIFICA%C3%87%C3%83O-DE-IMAGENS-DE-FACES.pdf>>

TRAN, M. Eigenface for Face Recognition Presentation. 2008. Disponível em: <[http://www.slideshare.net/minhkiller/eigenface-for-face-recognition-presentation/18-ulliDemo\\_liul](http://www.slideshare.net/minhkiller/eigenface-for-face-recognition-presentation/18-ulliDemo_liul)>