

**CENTRO UNIVERSITÁRIO DE ANÁPOLIS – UniEVANGÉLICA
BACHARELADO EM ENGENHARIA DE COMPUTAÇÃO**

**COMPARAÇÃO DE TÉCNICAS DE RECONHECIMENTO FACIAL NO CONTROLE DE
FREQUÊNCIA ACADÊMICA**

THAÍS TAVARES DE AMORIM

**ANÁPOLIS
2018**

THAÍS TAVARES DE AMORIM

**COMPARAÇÃO DE TÉCNICAS DE RECONHECIMENTO FACIAL NO CONTROLE DE
FREQUÊNCIA ACADÊMICA**

Trabalho de Conclusão de Curso II apresentado como requisito parcial para a obtenção de grau do curso de Bacharelado em Engenharia de Computação do Centro Universitário de Anápolis – UniEVANGÉLICA.

Orientador: Prof. Me. Marcelo de Castro Cardoso.


Anápolis
2018

THAÍS TAVARES DE AMORIM

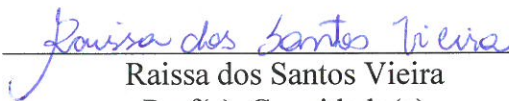
**COMPARAÇÃO DE TÉCNICAS DE RECONHECIMENTO FACIAL
NO CONTROLE DE FREQUÊNCIA ACADÊMICA**

Trabalho de Conclusão de Curso II apresentado como requisito parcial para a obtenção de grau do curso de Bacharelado em Engenharia de Computação do Centro Universitário de Anápolis – UniEVANGÉLICA.


Aprovado(a) pela banca examinadora em 13 de Dezembro de 2018, composta por:



Marcelo de Castro Cardoso
Presidente da Banca



Raissa dos Santos Vieira
Prof(a). Convidado(a)



Millys Fabrielle Araújo Carvalhaes
Prof(a). Convidado(a)

Dedico este trabalho à minha família (minha mãe, meu pai, minhas tias, primas e meus amigos), que me apoiaram e apoiam no desenvolvimento deste sonho.

AGRADECIMENTOS

Agradecimentos? Posh, são tantos!

Primeiramente, agradeço a Deus por me ajudar a chegar até aqui, me manter firme até o final.

Agradeço meus pais (Delzuita e Luiz) que tanto se dedicaram, que tantas vezes se colocaram de lado para que eu conseguisse chegar a este momento tão importante.

Agradeço aos amigos que sempre estiveram ao meu lado e me apoiaram e também os amigos que a graduação me trouxe, as várias risadas, mesmos que de desespero, aqueles momentos que serão eternizados para sempre em nossa memória.

Agradeço aos professores que nos motivaram, incentivaram e nos atenderam mesmo que as 3 horas da madrugada por causa de um simples ponto e vírgula (;) esquecido no final de cada código que fazia com que ele não compilasse.

Agradecimento em especial agradeço ao professor Marcelo de Castro Cardoso por aceitar esse desafio junto comigo e me orientar para que pudesse alcançar os objetivos deste projeto, mesmo que as vezes em cima da hora, na correria sempre estive e está disposto a contribuir com mais conhecimento.

Agradeço a professora Aline Dayane por ter sido praticamente uma mãe e nos salvar sempre no último minuto de LFA ou Compiladores e ainda nos aguentar as 3 ou 4 da manhã perguntando como seria implementado determinada funcionalidade.

Agradeço a professora Luciana Nishi por sempre ser a professora parceira, amiga e compartilhar risadas de momentos que serão levados da graduação pra vida, nos aguentar mandando mensagem, e-mail, implorando, Nishi pelo amor Deus deixa pra entregar na sexta ou na segunda e ser aquela professora que quando você chora por um trabalho lhe questiona de forma animadora: O que você faz de 00:00 (*meia noite*) as 06:00 da manhã?

Agradeço a todos que fizeram com que este sonho se tornasse realidade, sendo assim, podemos acreditar que tudo que a vida nos oferecerá no futuro será um SE-ENTÃO-SENÃO do que fizemos ontem e hoje!

```
import gratidao
import graduação

if TCC == "APROVADO"
    print (' Noites sem dormir NÃO
mais! Engenheiro você se TORNOU!');
```

“Seu trabalho vai preencher uma parte grande de sua vida, e a única maneira de ficar realmente satisfeito é fazer o que você acredita ser um ótimo trabalho. E a única maneira de fazer um excelente trabalho é **amar** o que você faz. “

Steve Jobs

Resumo

Identificar um indivíduo nos dias atuais é algo comum, essa identificação é realizada por meio do CPF (Cadastro de Pessoa Física) ou RG (Registro Geral). Porém, com os avanços tecnológicos esses meios podem ser substituídos pelas impressões digitais, impressões de pulso, reconhecimento de íris e/ou reconhecimento facial.

O objetivo deste trabalho é desenvolver uma proposta de controle de frequência acadêmica utilizando redes neurais, onde foi desenvolvido um algoritmo treinado para identificar indivíduos por meio de um banco de dados pré cadastrado. A proposta a ser desenvolvida visa atender o melhor controle de frequência, controle de acesso, segurança e comodidade da comunidade acadêmica da instituição.

Palavras-chave: Reconhecimento Facial, Reconhecimento de Padrões, Identificação de Indivíduos, Aprendizado de Máquina, Controle de Frequência

Abstract

Identifying an individual in the present day is a common occurrence, identification is performed through the CPF (Individual Registry) or RG (General Registry). However, with technological advances these means can be replaced by fingerprints, pulse impressions, iris recognition and / or facial recognition.

The objective of this work is to develop a proposal of academic frequency control using neural networks, where a trained algorithm was developed to identify individuals through a pre-registered database. The proposal to be developed aims to meet the best frequency control, access control, security and convenience of the institution's academic community.

Key words: Facial Recognition, Pattern Recognition, Individual Identification, Machine Learning, Frequency Control

Lista de Figuras

Figura 1: Espectro visível ao Olho Humano. 700 a 400 nm. Fonte: TORTORA, 2006	17
Figura 2: Anatomia do olho humano. Ilustração: BlueRingMedia Shutterstock.com.....	18
Figura 3: Visão Computacional para Reconhecimento de Objetos.....	19
Figura 4: Imagem em várias resoluções. a - Imagem original (n=1), b - (n=4), c - (n=8), d - (n=16) ...	21
Figura 5: Estrutura do neurônio biológico. Fonte: ARTERO, ALMIR OLIVETTE	26
Figura 6: Neurônio Artificial. Fonte: ARTERO, ALMIR OLIVETTE	26
Figura 7: Modelo de Traços Reconhecimento. Fonte: Internet.....	30
Figura 8: Transformação LBP. Fonte: PRADO, 2016.	32
Figura 9: Exemplos de Padrões LBP uniformes e não uniformes. Fonte: LI, S.; JAIN, 2011	33
Figura 10: Metodologia do Trabalho de Conclusão de Curso. Fonte: AMORIM, Thaís Tavares	37
Figura 11: Demarcações do Retângulo ao Detectar uma Face.....	38
Figura 12: Pessoas 1 e 2 convertidas em escala de cinza.	39
Figura 13: Pessoa 3, 4 e 5 convertidas em Escala de Cinza	40
Figura 14: Array de ID's, matriz de similaridade gerada.....	41
Figura 15: Classificadores gerados na fase de treinamento	41
Figura 16: Representação de Imagens Eigenfaces	42
Figura 17: 1º Tentativa de Reconhecimento com Eigenfaces	44
Figura 18: 2º Tentativa de Reconhecimento Facial com eigenfaces.....	45
Figura 19: Tentativas de identificação utilizando Fisherfaces	45
Figura 20: Tentativa de Reconhecimento com Fisherfaces.....	46
Figura 21: Tentativa de Treinamento Algoritmo LBPH	47
Figura 22: Tentativa de Reconhecimento com LBPH.....	48
Figura 23: Identificação utilizando LPBH	48
Figura 24: Imagens de Teste para Reconhecimento Facial.....	49
Figura 25: Faces de Teste Detectadas	50
Figura 26: Resultado da comparação de imagens	51
Figura 27: Avaliação do Algoritmo - Classificação.....	52
Figura 28: Tentativa de Detecção de Face já existente na base de dados	56
Figura 29: Identificação de Indivíduo com LPBH	56
Figura 30: Identificação de múltiplos usuários LPBH	57

Lista de Tabelas

Tabela 1: Variações de Parâmetros e Resultados Eigenfaces	54
Tabela 2: Resultados dos Parâmetros Fisherfaces	55
Tabela 3: Resultados dos Parâmetros LPBH	55
Tabela 4: Pontos Positivos e Negativos.....	57
Tabela 5: Comparativo de Resultados entre Algoritmos.....	58

Lista de Equações

Equação 1: Expressão Representativa. Fonte: AMARAL; GIRALDI; THOMAZ,2013.....	31
Equação 2: Expressão Representativa. Fonte: AMARAL, GIRALDI; THOMAZ, 2013.....	32

Lista de Abreviaturas e Siglas

IA	Inteligência Artificial
KNN	K – <i>Nearest Neighbors</i>
LDA	<i>Linear Discriminant Analysis</i>
LPBH	<i>Local Binary Patterns Histograms</i>
MIT	<i>Massachusetts Institute of Technology</i>
PCA	<i>Principal Component Analysis</i>
RNAs	Redes Neurais Artificiais

Sumário

1	Introdução	13
2.1	Visão Computacional.....	16
2.1.1	Olho Humano (Visão Biológica)	16
2.1.2	Sistema de Visão Computacional	18
2.2	Detecção de Imagens.....	19
2.2.1	Método Baseado em Conhecimento	20
2.2.2	Método Baseado em Características Invariantes.....	21
2.2.3	Método Baseado em Templates	22
2.2.4	Método Baseado em Aparência	22
2.3	Inteligência Artificial	23
2.4	Redes Neurais Artificiais	25
2.5	Reconhecimento de Padrões.....	28
2.5.1	Reconhecimento Facial	29
2.6	Algoritmos de Reconhecimento Facial utilizando Redes Neurais.....	31
2.6.1	Local Binary Patterns (LBPH).....	31
2.6.2	Algoritmo Eigenfaces	33
2.6.3	Algoritmo Fisherfaces	34
3	Desenvolvimento	36
3.1	Processo Metodológico	36
3.2	Coleta de Imagens	38
3.3	Treinamento do Algoritmo	41
3.4	Reconhecedor Eigenfaces.....	42
3.5	Reconhecedor Fisherfaces.....	45
3.6	Reconhecedor LPBH.....	46
3.7	Avaliação dos Algoritmos.....	49
4	Discussão de Resultados.....	54
5	Conclusão.....	59
5.1	Trabalhos Futuros	60
	Referências Bibliográficas.....	62

1 Introdução

Atualmente há necessidade de identificação de indivíduos em locais como por exemplo empresas, aeroportos, universidades, agências bancárias. Existem vários meios de identificação utilizados nos dias atuais, como senhas, cartões com chip e impressão digital (biometria). Os seres humanos possuem características biológicas particulares que podem ser utilizadas no processo de identificação, temos características como: impressão digital, retina, geometria da mão, voz, modo de andar, face e assinatura. Estudos apresentam que já pode ser comprovado que ao utilizar um sistema de reconhecimento facial podemos alcançar 95% de exatidão em uma identificação de ser humano. (BOMBARDELLI,2013)

Algumas décadas atrás era impensável construir máquinas ou dispositivos que pudessem “pensar” por conta própria, ou seja, que fossem capazes de aprender e a partir do aprendizado desenvolver resultados, sem a necessidade de um ser humano intervir em suas decisões. Porém, em 1950, o cientista da computação britânico Alan Turing já especulava sobre o surgimento de uma máquina pensante, com os avanços tecnológicos a capacidade de construir dispositivos capazes de aprender a simular as reações e decisões humanas estão vez mais próximas do que podemos imaginar.

No âmbito do Centro Universitário de Anápolis – UniEvangélica, os meios de identificação acadêmica são registrados de forma manual. Pensando em realizar melhorias, a instituição tem buscado constantemente automatizar os processos que são realizados no dia-a-dia. Em **2016** a instituição realizou a automatização do processo de realização de chamada, anteriormente realizada por meio de um diário de aula impresso onde o professor lançava a presença dos acadêmicos presentes em sala. Com essa automatização, o auxílio de sistema com a listagem de alunos permite que o professor informe se o acadêmico está presente ou não no período de aula, tudo de forma virtual e em tempo real. Em **2017**, para melhorar o acesso à instituição e controle de acesso, foi implantado o acesso por meio de cartão de acesso, onde o acadêmico necessita realizar o cadastro junto a secretária geral e portar um cartão de identificação para acessar a instituição. Ainda no ano de **2017**, sempre com pressuposto de melhoria, foi desenvolvido pelos acadêmicos do 8º Período de Engenharia de Computação para o evento SITES XVII (Seminário Interdisciplinar de Tecnologia e Sociedade) um sistema para realizar o controle de frequência a este evento, por meio do mesmo os acadêmicos presentes no evento validam sua presença

durante os dias do evento por meio de um breve cadastro e confirmam com os organizadores por meio de um código *Quick Response (QR Code)* gerado após o cadastro.

De acordo com REZENDE (2005), nossa capacidade de agir de forma inteligente é associada com o conhecimento que possuímos tornando evidente que a incorporação do conhecimento é fundamental para que sejam construídos sistemas inteligentes e computadorizados. Com base nas considerações realizadas acima, é possível realizar o controle de frequência acadêmica diária por meio de reconhecimento facial utilizando um algoritmo inteligente?

Através deste projeto de pesquisa, objetivou-se elaborar uma proposta de controle de frequência acadêmica para a instituição por meio de reconhecimento facial. A pesquisa foi realizada por meio do estudo das tecnologias existentes, comparação de algoritmos de reconhecimento facial e a breve elaboração de um algoritmo com base nos estudos realizados que seja capaz de extrair informações de uma imagem e posteriormente reconhece-la, seja uma foto ou uma imagem captada de uma câmera.

A inteligência artificial (IA) busca desenvolver novos métodos de resolução de problemas. Um dos métodos é o desenvolvimento de redes neurais capazes de executar atividades realizadas por humanos por meio de aprendizagem. A computação ubíqua prevê um crescimento tecnológico que chegue ao ponto de haver uma interação total, cada vez mais presente na vida das pessoas, de forma que as interfaces sejam capazes de armazenar informações e literalmente, aprender a partir das funções realizadas anteriormente, podendo compartilhar dados, informações e conhecimento, sendo assim, sem que percebamos esta tecnologia fará parte da evolução humana (JUNIOR, 2014).

Existem diversas maneiras de comprovar a identidade do usuário, porém, na maioria dos casos é comum a necessidade de utilizar *hardwares* robustos e com valorização alta de mercado para realizar este processo, como por exemplo no caso de leitores biométricos que possuem um custo elevado para utilização do *hardware*. A utilização de um algoritmo inteligente capaz de aprender e ser treinado a ler expressões, reações e variações de uma face pode aumentar a comodidade, veracidade das informações e a segurança da identificação. De acordo com HALL, 1979 cada ser humano possui um padrão único que pode caracterizá-lo e diferenciá-lo de outro indivíduo, garantindo sua identificação. Este processo pode ser realizado

por meio do treinamento de algoritmo com base na captura de imagens ou por meio de câmeras em tempo real.

Em um ambiente onde o controle de frequência é realizado por meio de registros manuais ou com auxílio de sistemas para lançamento de informações, a construção de um algoritmo inteligente pode facilitar ou gerar melhor conforto ao usuário que tem a necessidade de utilizar tais meios de administração. Sendo assim, a utilização de controle de frequência por reconhecimento facial advém da necessidade de maior comprometimento e maior confiabilidade na gestão de acesso à sala de aula e à instituição.

O acesso por meio de crachá ou cartão de identificação, que são objetos pessoais e intransferíveis, podem facilmente ser utilizados por terceiros, o que seria identificado como uma falha de segurança ou roubo de identidade. Um caso comum de tal falha, por exemplo, seria um usuário registrar ponto de outra pessoa ou acessar as dependências da instituição utilizando apenas o crachá de identificação de outro indivíduo ou um acadêmico que assina a ata de presença de uma determinada matéria por outro acadêmico que não esteja presente no período de aula ou prova.

Levando em consideração os aspectos acima abordados, por meio do estudo de caso realizado foi possível notar a necessidade de melhorar o controle de acesso e frequência acadêmica da instituição, para que haja um controle efetivo de entrada, saída e permanência na mesma por parte dos acadêmicos, docentes e funcionários. Este projeto propõe uma forma de controle de frequência acadêmica mais efetiva, visando o aumento da veracidade do controle, segurança e a comodidade na sala de aula e dependências da instituição.

No capítulo 2 será apresentada a fundamentação teórica necessária para realizar o levantamento de informações deste projeto, no qual poderemos entender alguns conceitos necessários para implementação do projeto. No capítulo 3 abordaremos o passo a passo do funcionamento dos algoritmos de reconhecimento facial, como funcionam, o que fazem e pôr fim a diferença dos tipos de algoritmos, pontos positivos e negativos. No capítulo 4 são descritos os Resultados e uma breve discussão entre os resultados obtidos em nossos testes e o que os demais autores falam sobre estes algoritmos e finalmente o último capítulo contém uma breve conclusão de quais foram os resultados alcançados e aprendido com o desenvolvimento deste projeto.

2 Fundamentação Teórica

Para realizar a proposta de melhoria do controle de frequência acadêmica, faz-se necessário entender aspectos específicos relacionados à: Visão Computacional, Detecção de Imagens, Reconhecimento de Padrões, Reconhecimento Facial, Inteligência Artificial, Redes Neurais e Algoritmos de Reconhecimento Facial utilizando Redes Neurais. O que requer uma prévia argumentação teórica para que, uma vez que as definições estejam apresentadas, haja entendimento, permitindo a compreensão da proposta e a análise dos resultados apresentados.

2.1 Visão Computacional

A visão computacional é considerada um conjunto de dados e técnicas que tornam sistemas de computador capazes de extrair informações de imagens. É a tecnologia ou ciência responsável pela forma como um computador enxerga o meio a sua volta, de forma a extrair informações significativas a partir das imagens capturadas no ambiente, seja por meio de uma câmera, vídeo, sensores, scanners ou outros dispositivos. As informações extraídas permitem reconhecer, manipular e pensar sobre os objetos que compõem uma imagem capturada. (MILANO; HONORATO, 2010).


A visão computacional envolve e pode ser aplicada em diversas áreas de conhecimento, como: inteligência artificial, aprendizado de máquina (visão cognitiva), processamentos de sinais, física (ótica), matemática, neurobiologia (visão biológica), robótica (visão de robôs) e ainda outras áreas. Além de ser utilizada nessas áreas de conhecimento a visão computacional pode ser utilizada em aplicações para realizar reconhecimento de padrões ou pessoas, segurança de ambientes, visão de robôs, desenvolver robôs capazes de perceber o ambiente a sua volta, identificar objetos e traçar rotas ou evitar acidentes, assim como várias outras atividades que dependem de visão biológica.

2.1.1 Olho Humano (Visão Biológica)

Os olhos humanos são capazes de capturar a luz refletida por tudo que está a sua volta. Essa luz se transforma em sinais elétricos que são enviados ao nosso cérebro através do nervo óptico e lá são interpretadas como imagens. Essa interpretação de imagens no cérebro compõe o sentido da visão.


A visão funciona através do processamento de dados recebidos pelo encéfalo, por meio dos receptores sensoriais ativados pela luz. No cérebro essas informações são armazenadas. Dessa forma, ocorre o fenômeno ótico, considerado um evento físico o que gera uma relação entre o que é visto pelo espectador e a estrutura que apresenta, o olho enxerga por meio das amplitudes de ondas eletromagnéticas, um evento anatômico. Esse grande número de informações do ambiente é conduzido a luz por meio dos olhos, o órgão que possui os receptores sensoriais chamados de fotorreceptores. Os olhos detectam uma reduzida parte do espectro eletromagnético, são sensíveis a radiações que tenham um comprimento de onda entre 700 a 400 nm. Esses limites equivalem respectivamente à cor vermelha (700 nm) e violeta (400 nm), transitando pelas cores amarela, verde e azul conforme apresentado na Figura 1. (TORTORA; GRABOWSKI, 2006)

Figura 1: Espectro visível ao Olho Humano. 700 a 400 nm. Fonte: TORTORA, 2006



Os estímulos que são captados pelos olhos, são assimilados pelo cérebro que esboça uma imagem tridimensional única. No olho, está presente o Cristalino que possui a função de adaptação para suprir as necessidades solicitadas pela visão humana, funcionando como se fosse uma lente. A retina que contém as células fotorreceptores que são responsáveis por detectar as cores e os estímulos luminosos. A córnea (primeira e mais poderosa superfície que a luz atravessa) e os nervos ópticos (meio de transporte das informações entre a retina e o cérebro) conforme representado na Figura 2 (TORTORA; GRABOWSKI, 2006).

Figura 2: Anatomia do olho humano. Ilustração: BlueRingMedia Shutterstock.com




2.1.2 Sistema de Visão Computacional

Ver envolve mais do que apenas analisar uma imagem, envolve a percepção em outras frentes assim como várias análises necessárias. O ser humano usa cerca de dois terços do cérebro para processar uma imagem, por isso não é de se admirar que um computador precise usar mais do que apenas o reconhecimento de imagem para obter sua visão de forma correta.

O reconhecimento realizado pelo computador, é mais do que a análise de uma imagem, é a análise de cada pixel existente em uma imagem, faz parte de um processo que vai desde o reconhecimento de objetos e características até análise de textos e sentimentos. O reconhecimento de imagens utilizado atualmente, geralmente é utilizado para reconhecer objetos simples, como sapatos, cadeiras e outros objetos conforme representado na Figura 3 (TORTORA; GRABOWSKI, 2006).

Figura 3: Visão Computacional para Reconhecimento de Objetos



A visão computacional vai além, ela é utilizada em seu sentido mais pleno, buscando ser utilizada em nosso cotidiano e nos negócios para conduzir todos os possíveis tipos de tarefas, como: identificar produtos e comprá-los, identificar doenças em um raio X, entre outras tarefas. É um processo de modelagem e/ou replicação da visão humana usando um hardware ou um software. Ela realiza a reconstrução e compreensão de uma cena 3D partindo de suas imagens 2D em termos de propriedade da estrutura na cena.

Para que uma imagem possa ser analisada por um sistema de visão computacional ela precisa ser detectada e identificada, por isso precisamos entender o funcionamento da Detecção de Imagens.

2.2 Detecção de Imagens

Uma das Tarefas que precisam ser realizadas quando começamos a trabalhar com o Reconhecimento de Faces é detectar a presença de uma face em uma determinada imagem, seja estática ou em vídeo. Esta é uma tarefa extremamente complexa, porque podem ocorrer variações de luminosidade, fundos e objetos que podem sobrepor parcialmente à face que deverá ser localizada.

O principal objetivo da detecção em movimento é conseguir localizar objetos em primeiro plano para extrair informações úteis ao sistema como trajetória, orientação de velocidade, informações pessoais como idade, sexo e outras. O desafio da detecção de imagens é resolver a possível perda de informações por causa de

planos de fundos complexos ou dinâmicos, mudanças de iluminação, sombras entre outros fatores.

De acordo com YAN (2002) as técnicas de detecção de faces, apesar de possuírem diferentes abordagens alguns problemas são comuns, como:

- a) **Pose:** As imagens de face variam de acordo com a posição da câmera que registrou a imagem.
- b) **Expressão Facial:** A expressão influencia diretamente na aparência da imagem de face.
- c) **Presença de elementos Estruturais:** a presença de elementos como barba, bigode, óculos, podem modificar as características em termo de tamanho, luminosidade e outros.
- d) **Ocultação:** no caso de imagens feitas em ambientes não controlados as faces podem aparecer, parcial ou totalmente sobrepostas, por objetos ou até mesmo por outras faces.
- e) **Qualidade da Imagem:** quando a imagem é formada, fatores de iluminação (espectro, fonte de distribuição e intensidade) e características da câmera (resposta de sensor e lentes) podem afetar a aparência da face.

Quando falamos de um ser humano reconhecer outro, é uma ação que realizamos naturalmente em nosso dia-a-dia, quando captamos a imagem uma pessoa, automaticamente essa imagem fica armazenada em nossa memória, embora não relembremos no momento, a imagem armazenada em nossa memória nos faz lembrar que aquela face é conhecida, ou similar à de uma pessoa.

Existem vários métodos de detecção de faces em imagens em escala de cinza assim como em imagens coloridas. Os métodos são classificados em quatro categorias conforme apresentado por Yang (2002).

2.2.1 Método Baseado em Conhecimento

De acordo com Yang (2002), sabemos que as faces humanas possuem determinadas componentes comuns, como: uma boca, um nariz e dois olhos. Esses elementos são distribuídos de maneira específica sobre a face humana, partindo deste conhecimento é possível partir para estabelecimento de regras que podem identificar uma face humana.

Imagens em múltiplas resoluções são formadas por meio da aplicação da média em um conjunto de *pixels*, como é apresentado na Figura 4. Considerando n um determinado número de *pixels*, geralmente contidos em uma janela quadrada de $n \times n$ *pixels*, substitui-se o valor de cada pixel pelo valor médio dos pixels contidos dentro da janela.

Figura 4: Imagem em várias resoluções. a - Imagem original ($n=1$), b - ($n=4$), c - ($n=8$), d - ($n=16$)



A principal desvantagem desse método é que quando a imagem possui um fundo complexo a detecção de face e as características faciais ficam comprometidas. A detecção de face é feita pela análise de picos presentes na projeção.

2.2.2 Método Baseado em Características Invariantes

Diferente do método baseado em conhecimento, este método busca encontrar características invariantes na face. Este método é baseado na capacidade do ser humano identificar facilmente faces e objetos em diferentes condições e ambientes. Componentes como: sobrancelhas, olhos, nariz, boca e o contorno da face conseguem ser extraídos utilizando detectores de bordas. Para Yang (2002), a principal desvantagem desse método é que os componentes faciais podem ser corrompidos de acordo com as condições de iluminação, ruído e obstrução, dificultando assim a eficiência da abordagem.

Uma característica invariante utilizada normalmente para identificar objetos é a forma. A detecção através da forma baseia-se na capacidade que os seres humanos têm de reconhecer um objeto que ora tem uma forma determinada e em outro momento apresenta totalmente diferente. A cor da pele são características bastante usadas para detecção de imagens. As informações sobre a pele constituem em uma importante ferramenta de identificação de áreas da face e os componentes faciais específicos.

Para rotular os *pixels* da pele são utilizados diversos espaços de cores existentes: RGB, RGB normalizado, CMY, HSV9 ou HSI, CIEL LUV entre outros. A pele humana tende a formar um *cluster*¹ no espaço de cores, podendo ser modelada por uma distribuição Gaussiana, característica que poderia ser utilizada para localizar faces em uma imagem colorida.

2.2.3 Método Baseado em Templates

O objetivo do método baseado em template é procurar uma imagem, utilizando o molde padrão que é definido de forma manual, ou padronizado por uma função. A maneira mais comum de modelar a forma do objeto é descrevendo por meio de seus componentes geométricos básicos, como quadrados, círculos ou triângulos. A detecção do objeto consiste em localizar a melhor simetria entre o objeto e a imagem e seu *template* (molde). (YANG, 2002)

No caso da detecção de face o *template* geralmente utilizado é aquele que trata a face como uma elipse, sendo aplicado também em sequência de imagens. A técnica de *Templates* é bastante flexível, sendo assim, ela pode ser utilizada para detectar qualquer objeto que possa ser representado por formas geométricas. (YANG, 2002).

2.2.4 Método Baseado em Aparência

O método baseado em aparência, os modelos são definidos utilizando técnicas de treinamento e aprendizagem, não utilizando nenhum conhecimento ou características sobre o objeto previamente informado. Assim as informações necessárias para realizar a detecção são retiradas de um conjunto de imagens (YANG, 2002).

O método autofaces proposto por Turk e Pentland (1991) é baseado na análise de componentes principais (*Principal Component Analysis – PCA*) juntamente com a transformação de Karhunen-Loève (KLT) para reconhecimento e detecção de face. Por meio da transformação KLT é possível encontrar vetores que podem melhorar a representação da imagem, esses vetores por sua vez são denominados autofaces por sua semelhança com imagens de face. (KOVAC, 2003)

¹ *Cluster* é um termo inglês que significa “aglomeração”. No caso da computação o termo define uma arquitetura de sistema capaz combinar vários para trabalharem em conjunto ou pode denominar o grupo em si de computadores combinados.

Sendo assim, vimos os principais métodos de detecção facial encontradas em literaturas que visam identificar a presença de faces em uma imagem. Cada método se propõe identificar uma face ou faces presentes em uma imagem com a maior taxa de acerto possível, porém, cada um dos métodos apresenta suas vantagens e desvantagens. Métodos que são vistos como mais robustos tendem a ter implementação mais complexa e maior custo computacional, como é o caso do autofaces que apresentamos nesta seção. Métodos que utilizam a cor da pele por exemplo são de implementação mais simples, porém, os resultados dependem dos espaços de cores utilizados.

Realizado o processo de detecção da imagem é preciso utilizar técnicas de reconhecimento para extrair informações da imagem e assim podemos apresentar ao usuário. Antes de entender sobre a extração de informações em imagens vamos analisar sobre os meios de Inteligência Artificial que fazem que seja possível realizar a identificação de indivíduos.

2.3 Inteligência Artificial

A inteligência artificial (IA) é uma área de estudo da computação que se interessa pela criação de sistemas que possam apresentar um comportamento inteligente e realizar tarefas complexas com um nível de competência que é equivalente ou superior à de um ser humano. De acordo com ARTERO (2009):

As expectativas da área são muito boas, pois nos últimos anos a IA tem se tornado intensamente popular, as máquinas com diferentes níveis de inteligência já começaram a ser utilizadas em diversas áreas. É possível assim, que no futuro não muito distante elas estejam presentes em praticamente todas as atividades humanas.

Para ANTERO (2009) a inteligência artificial está associada à capacidade das máquinas “pensarem” como os seres humanos que tem o poder de aprender, raciocinar, perceber e decidir de forma inteligente. Em 1956, John McCarthy, professor universitário, criou um termo para descrever um mundo em que as máquinas poderiam “resolver os tipos de problemas que hoje são apenas resolvidos por seres humanos.” O desejo de construir máquinas inteligentes e que sejam capazes de espelhar a capacidade humana na forma de pensar ou agir vem de anos atrás. Podemos comprovar tal afirmação por meio da existência de máquinas autônomas e através de

personagens místicos que vemos em seriados, filmes e desenhos, como por exemplo o Frankenstein uma obra de Mary Shelley (1797 – 1851).

Quando utilizamos um *smartphone*, por exemplo, já estamos lidando com IA. Porém, por trás de cada solicitação existe uma combinação de tecnologias que faz com que a IA funcione, gerando uma expectativa maior no usuário para máquinas inteligentes e nos dispositivos que usamos. A inteligência artificial é a mudança tecnológica mais poderosa da área da computação. Além de deixar as escolhas mais inteligentes, ela também integra a análise preditiva² aos aplicativos que usamos todos os dias, conectando diversos ambientes da vida, como: casa, trabalho, viagens entre outros. A IA nos acompanha em nosso dia-a-dia, prevê as necessidades e lembra de tarefas importantes.

É provável que utilizemos IA em nosso dia-a-dia sem ao menos percebermos, como por exemplo:

- a) Aplicações como a Siri (Utilizada no sistema IOS) ou a Cortana (Utilizada no sistema Windows) utilizam processamento de voz para atuar como assistente pessoal; (TECMUNDO,2017)
- b) O *Facebook* utiliza o reconhecimento de imagem para recomendar marcações em fotos, por meio de reconhecimento de padrões; (TECMUNDO,2017)
- c) A *Amazon* assim como outros softwares de venda na internet, realizam recomendações personalizadas de produtos utilizando algoritmos de aprendizado de máquina (Com base na busca comum de produtos realizadas pelo usuário); (FOLHA DE SÃO PAULO, 2017)
- d) O *Waze* e o Google Maps, preveem as melhores rotas a partir da sua localização com apenas um clique, enquanto carros com piloto automático usam as técnicas de IA para evitar engarrafamentos e colisões; (CANALTECH, 2017)
- e) O Google consegue preencher automaticamente as buscas utilizando recursos de inteligência artificial e prevê o que você quer pesquisar com grande precisão. (CANALTECH, 2017)
- f) A China desenvolveu um sistema para detecção pela forma do indivíduo andar (Oito pontos são avaliados, como tamanho do passo, velocidade e postura. O

² Análise Preditiva: É a capacidade de usar dados, algoritmos e técnicas de *machine learning* na tentativa de prever situações futuras.

responsável pelo projeto afirma que o índice de acerto pode chegar a 95%). (g1.globo.com.br, 2015)

A IA abrange quase todos os campos da vida humana, até mesmo tarefas específicas, como: jogos de lógica, direção de um carro em estrada movimentada, diagnóstico de doenças, demonstração de teoremas matemáticos. De acordo com Russell e Stuart (2013) “este é um verdadeiro campo universal, a IA é um campo relevante para todas as tarefas intelectuais”.

As primeiras ferramentas de IA a serem desenvolvidas adquiriam o conhecimento que eram explicitadas pelos especialistas de determinadas áreas, o que era similar a programar um sistema computacional para resolver um problema.


Grande parte dessas ferramentas, possuem limitações, porque assumem que os conhecimentos adquiridos e as informações disponíveis sejam corretas e completas com relação ao problema, o que normalmente não acontece. Dessa forma são orientadas por informações qualitativas, o que pode ser difícil de ser medido levando assim vários pesquisadores que enfrentam limitação dar início ao processo de desenvolvimento de ferramentas baseadas na forma que o cérebro humano funciona.

2.4 Redes Neurais Artificiais

As redes neurais artificiais (RNAs) foram desenvolvidas, por volta da década de 40, pelo neurofisiologista Warren McCulloch, do MIT (*Massachusetts Institute of Technology*), e pelo matemático Walter Pitts, da Universidade de Illinois, dentro do meio cibernético fizeram uma analogia entre células nervosas vivas e o processo eletrônico em um trabalho apresentado sobre “Neurônios Formais”. O trabalho consiste em um modelo de resistores variáveis e amplificadores representando conexões sinápticas de um neurônio biológico. (BRAGA; CARVALHO; LUDERMIR, 2007).


De acordo com ARTERO, (2009) “os neurônios são formados por uma membrana celular, um citoplasma e um núcleo”, além de outros componentes conforme Figura 5.

Figura 5: Estrutura do neurônio biológico. Fonte: ARTERO, ALMIR OLIVETTE



Baseado no comportamento do neurônio biológico, o neurônio artificial é uma estrutura lógica-matemática que procura recriar o comportamento e as funções de um neurônio biológico. Dessa forma, os dendritos são substituídos por entradas, cujas ligações como um corpo celular artificial, são realizadas através de elementos chamados de *peso* (simulação de sinapses). Os estímulos captados pelas entradas são processados pela função de soma, e o limiar de disparo do neurônio biológico é substituído pela função de transferência conforme modelo representado na Figura 6.

Figura 6: Neurônio Artificial. Fonte: ARTERO, ALMIR OLIVETTE



As RNAs têm como característica principal a capacidade de aprendizagem por meio de exemplos, ou seja, através de ajuste de pesos. De acordo com McLaren e Mendel (1970), o aprendizado pode ser definido como:

Processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre.

Outro fator que é importante é a maneira na qual a rede neural se relaciona com o ambiente. Nesse contexto, existem as formas de aprendizado:

- a) **Aprendizado Supervisionado:** É necessário um agente externo que indique à rede a resposta desejada para o padrão de entrada, ou seja, o sistema possui acesso à “resposta correta” durante o processo de treinamento.
- b) **Aprendizado Não-Supervisionado:** Não há necessidade de um agente externo indicando a resposta desejada para os padrões de entrada, ou seja, o sistema reconhece padrões nos dados de entrada, mesmo sem nenhum *feedback* de saída.
- c) **Reforço:** É um crítico externo avaliando a resposta dada pela rede, ou seja, o sistema cria uma hipótese sobre a solução do problema e determina se essa hipótese foi boa ou ruim.

O modelo **Supervisionado** consiste em ajustar os pesos e os *thresholds*³ de suas unidades para que a classificação desejada seja obtida. Quando o padrão é apresentado pela primeira vez à rede, ela produz uma saída.

Após medir a distância entre a resposta atual e a desejada, são realizados ajustes apropriados nos pesos das conexões de modo a reduzir esta distância. Este procedimento é conhecido como a Regra de Delta.

O modelo **Não-Supervisionado** ou **Auto-Organização** simula o processo da plasticidade cortical, onde em uma rede neural artificial é implementado em uma rede neural do tipo Kohonen, que possui certas similaridades funcionais com redes neurais biológicas, como é o caso da auto-organização da rede, processo fundamental nos sistemas orgânicos vivos. Para que uma rede seja devidamente treinada é necessário que seja primeiramente disponibilizado informações para que ela seja capaz de aprender. Na fase de treinamento, os neurônios da camada de saída competem para serem os vencedores a cada nova interação do conjunto de treinamento, ou seja, sempre que é apresentada à rede neural uma entrada qualquer, existe uma competição entre os neurônios da camada de saída para responder a entrada apresentada naquele momento. Esse aprendizado, nada mais é do que modificações sucessivas nos pesos dos neurônios de forma que estes classifiquem as entradas apresentadas. Compreendemos então que a rede neural "aprendeu" quando ela passa a reconhecer todas as entradas apresentadas durante a fase de treinamento.

³ *thresholds* é o valor mínimo que pode ser detectado pelos dispositivos

O modelo de aprendizagem por **reforço** é uma forma de aprendizado não-supervisionado que ensina como mapear estados para ações, de modo a maximizar (minimizar) um sinal numérico de retorno, que representa a soma total de todas as recompensas (punições) decorrentes das ações tomadas. Não são ditas ao agente de aprendizagem quais ações devem ser tomadas, assim como ocorre em outras abordagens. O agente deve descobrir quais ações resultam nas maiores recompensas (menores punições), a partir das percepções do ambiente, representadas por estados, que lhe são apresentadas. Para cada ação tomada, uma avaliação do seu resultado, na forma de recompensa ou punição, é apresentada ao agente pelo ambiente.

O processo de aprendizagem tem por finalidade orientar o agente a tomar as ações que venham a maximizar (minimizar) as recompensas (punições) recebidas.

De acordo com ARTERO, (2009):

Embora as redes neurais possam ser usadas para resolver vários problemas práticos, a sua maior utilização é na resolução de problemas que podem ser classificados como o reconhecimento de padrões, o que inclui uma ampla gama de aplicações, como o reconhecimento de voz, imagens (faces, impressões digitais) e objetos gerais.

Essa afirmação reforça a utilização de redes neurais para realização do reconhecimento facial, o que nos leva a entender mais sobre os tipos de reconhecimento, especificamente mais sobre Reconhecimento de Padrões e Reconhecimento Facial.

2.5 Reconhecimento de Padrões

De acordo com HALL (1979), um padrão pode ser considerado um conjunto de características semelhantes, ou podem ser consideradas também como a descrição de um problema recorrente para a qual existe uma solução que pode ser reutilizada em situações diferentes, de maneiras diferentes.

O objetivo do reconhecimento de padrões é extrair, identificar e detectar elementos presentes em uma imagem, para que possa ser realizada a classificação do objeto, controle de qualidade, compactação de dados e ainda outras ferramentas tecnológicas (HALL,1979). No reconhecimento de Padrões, temos obtenção de:

- a) Descrições:** Visa realizar a detecção de tipos de elementos na imagem, não tendo a preocupação em classificar os elementos em categorias. A obtenção de descrições pode ser utilizada para realizar a detecção de

vetores de uma imagem para realizar a segmentação e detecção dos elementos.

- b) Classificações:** Consistem na atribuição de padrões a um conjunto de classes pré-definidas por métodos. Esse reconhecimento é obtido por meio da abstração, onde se descarta os detalhes que não são essenciais e dá prioridade aos detalhes relevantes que são tidas como características definidoras da classe.

Quando pensamos no ser humano para realizar reconhecimento de padrões, parece algo bem simples, coletar informações, realizar algumas comparações e assim transmitir os resultados ou identificar um indivíduo. Para a IA o reconhecimento de padrões não é apenas uma tarefa trivial ou simples, pois não existe máquina capaz de se igualar a capacidade de reconhecimento do ser humano.

Um exemplo de reconhecimento facial por padrões é o reconhecimento utilizado pelo *facebook*, onde a tecnologia analisa os pixels das fotos e gera uma série de números, chamados de *template*. Ao receber novas fotos e vídeos, o sistema é capaz de comparar com os números gerados anteriormente e identificar o rosto do indivíduo no momento do *post* (TECHTUDO, 2017).

2.5.1 Reconhecimento Facial

Reconhecimento Facial é considerada uma área promissora, sendo por meio da análise de imagens ou vídeos, abrangendo diversas disciplinas da área de computação, como: Processamento de Imagens, Visão Computacional, Redes Neurais, entre outras. Nos tempos atuais, é comum aplicações que necessitem de identificação humana o reconhecimento facial possui várias vantagens sobre as outras tecnologias existentes como reconhecimento por voz, ou até mesmo utilização de digital (LI, S.; JAIN, 2005).

O Reconhecimento Facial é a técnica de biometria baseada nos traços do rosto da pessoa conforme apresentado na Figura 7. O ser humano pode reconhecer o rosto de outro com facilidade isso não é algo incomum nos tempos atuais, mesmo que sejam pessoas bem parecidas o ser humano é capaz de discernir a diferença entre um e outro. O rosto do ser humano é formado por diversas características, chamados de pontos notais. Existem em média 800 pontos notais no rosto de um indivíduo, como por exemplo: a distância entre os olhos, o comprimento do nariz, o tamanho do queixo e a linha da mandíbula. Cada um desses pontos pode ser avaliado e

armazenado em uma base de dados, o que forma uma assinatura facial de determinado indivíduo (LI, S.; JAIN, 2005)

Figura 7: Modelo de Traços Reconhecimento. Fonte: Internet



Para um programa de computador, antes de realizar a extração dos pontos notais do indivíduo, é necessário fazer o rastreamento da imagem capturada ou vídeo para detectar a localização e a posição do rosto. Após essa etapa é possível calcular os pontos, que requer a correta posição dos elementos da face, como: nariz, boca e olhos. O rastreamento da imagem é realizado por meio de uma imagem capturada anteriormente por uma câmera, webcam ou outro dispositivo e que tenha sido armazenada. Com essa imagem é possível aplicar filtros para detectar as formas que se aproximam ou assemelham com a cabeça humana, ou seja, com as características físicas comuns da face humana, realizando o rastreamento do rosto do indivíduo (ZHAO, 2003).

O rastreamento é baseado em formas, ou características comuns do rosto de todas as pessoas, admitindo variações. A extração das características por outro lado calcula as especificidades de cada indivíduo, buscando os detalhes que diferenciam as pessoas.

Um sistema de reconhecimento facial advém de três etapas (Zhao, 2003).

- a) Captura: coleta dos pontos nodais gerando assinatura facial;
- b) Normalização da assinatura facial para que tenha o mesmo padrão das assinaturas faciais já existentes;
- c) Comparação da assinatura facial com as já existentes no banco de dados e geração de nota de similaridade.

Apesar de o reconhecimento facial ser uma técnica prática, alguns inconvenientes tais como: uso de bigode, óculos de sol, chapéus, bonés ou até mesmo

expressões faciais podem prejudicar a identificação de uma pessoa. Porém, continua sendo válido devido ao reconhecimento de interações visuais.

Para realizar o reconhecimento facial é possível utilizar duas estruturas:

- a) **Detecção da face:** Inserida uma imagem o algoritmo detecta a face na imagem, sendo possível extrair várias faces de uma imagem
- b) **Reconhecimento da face:** cada detalhe ou face encontrada é comparado com as demais faces encontradas no banco de dados, sendo assim, informa a pessoa com certo grau de confiança.

A eficiência de um sistema de reconhecimento facial pode ser medida pela porcentagem de acertos na identificação de pessoas o que pode variar de acordo com a técnica utilizada durante o processo de identificação. Para que uma rede seja treinada para realizar o reconhecimento de um ser humano é necessário aplicação de um algoritmo de treinamento, sendo assim, será realizado a análise de três algoritmos mais utilizados na atualidade para reconhecer imagens (ZHAO,2003).

2.6 Algoritmos de Reconhecimento Facial utilizando Redes Neurais

2.6.1 Local Binary Patterns (LBPH)

O LBPH foi originalmente desenvolvido para realizar análise de texturas, no entanto, com o passar do tempo, passou a ser utilizado para extração de características no processo de reconhecimento e classificação de imagens faciais. O LBP lê os *pixels* de uma imagem levando em consideração a matriz, normalmente do tamanho 3 x 3, sendo que o pixel central da matriz é utilizado como limiar para definir o valor dos *pixels* vizinhos, os quais são definidos de forma binária (AMARAL; GIRALDI; THOMAZ, 2013).

Dessa forma, uma matriz com valores binários resultantes da comparação: valor binários 1 nos vizinhos que tem valor superior ou igual ao *pixel* central e 0. A limiarização do descritor $LBP = \{E_1, E_2, \dots, E_8\}$ é obtido por:

Equação 1: Expressão Representativa. Fonte: AMARAL; GIRALDI; THOMAZ,2013

$$E_i = \begin{cases} 0, & \text{se } V_i < V_0 \\ 1, & \text{se } V_i \geq V_0 \end{cases}$$

Os valores dos *pixels* na vizinhança limiarizada são multiplicados pelos pesos dados como *pixels* correspondentes. Feito esta etapa, realiza-se a soma dos valores, resultando em um valor do código LBP

Equação 2: Expressão Representativa. Fonte: AMARAL, GIRALDI; THOMAZ, 2013

$$N_{LBP} = \sum_{i=1}^8 E_i \cdot 2^{i-1}$$

Posteriormente, um histograma é criado para computar as ocorrências dos diferentes códigos LBP de todos os *pixels* da imagem. Formando o vetor de características LBP, que caracteriza a imagem da textura. A maior diferença entre TU e o LBP é o fato de o segundo possuir apenas $2^8 = 256$ códigos resultantes.

O operador LBP é robusto contra as transformações monótonas em escala de cinza. Podemos de uma maneira fácil observar isso olhando para uma imagem artificialmente modificada como mostra a Figura 8.


Figura 8: Transformação LBP. Fonte: PRADO, 2016.



Sendo assim, podemos incorporar as informações espaciais no modelo de reconhecimento de um rosto. A proposta de Ahonen, Hadid e Pietkaainen (2004,2006) é que a região facial é dividida em sub-regiões, em cada uma dessas sub-regiões é aplicada o operador LBPu2 (Padrões Binários Uniformes) e do resultado é gerado um histograma, contendo os padrões de textura.

Para que um padrão LBP seja considerado uniforme (LBPu2), ele deve conter seu valor binário no máximo duas transições de valores. O padrão 00110000 não é considerado uniforme por ter apenas duas transições, no caso do padrão 10011011 não é uniforme por apresentar quatro transições. Na Figura 9, são apresentados exemplos de padrões uniformes e padrões não uniformes.

Figura 9: Exemplos de Padrões LBP uniformes e não uniformes. Fonte: LI, S.; JAIN, 2011



Com a proposta de um operador LBPu2 com uma vizinhança de 8 *pixels* a quantidade de padrões é reduzida de 256 possibilidades para 59, sendo 58 para padrões uniformes e outra para totalizar a incidência dos padrões não uniformes. Estes padrões uniformes são definidos pela rotação e quantidade de “1”s. (LI, JAIN, 2011).

2.6.2 Algoritmo Eigenfaces

Proposto por Turk e Pentland (1991), o algoritmo Eigenfaces, um dos algoritmos utilizado para reconhecimento facial, consiste em duas fases: aprendizagem e reconhecimento. O Eigenfaces utiliza imagens de treinamento para aprender um modelo de face. Criando vetores através da técnica PCA (*Principal Component Analysis*), que é responsável por treinar a base de dados de imagens, transformando as informações visuais em vetores, que representam pontos marcantes na imagem, esses pontos podem ser utilizados para detecção de padrões, objetos e faces humanas. (TURK; PENTLAND, 1991).

O Eigenfaces busca extrair informações relevantes de uma imagem facial, configurado da forma mais eficiente possível, comparando a similaridade da face

configurada com uma base de modelos pré treinada. De forma matemática o Eigenfaces busca encontrar os componentes principais da atribuição das faces ou nos autovetores da matriz de covariância do conjunto de imagens, tratando assim a imagem como vetor (TURK; PENTLAND, 1991).

A dimensão de uma imagem é dada por meio do número de *pixels* contidos na imagem. O PCA faz o filtro da imagem, realizando o armazenamento apenas das características relevantes para o reconhecimento, eliminando os *pixels* que tenham ruídos (variação de brilho, distorções provocadas por compactação da imagem). Os *pixels* são armazenados como informações úteis formando assim o subespaço da imagem.

Na parte de reconhecimento, é reduzida a dimensão da imagem de entrada do subespaço encontrado durante a aprendizagem. Posteriormente a imagem do rosto desconhecido ser mostrado no subespaço, o algoritmo faz o cálculo da distância entre ela e cada imagem armazenada no treinamento. A saída é um ponteiro para a imagem mais próxima, ou seja, com menor distância do subespaço. (TURK; PENTLAND, 1991).

Durante o processo de treinamento, o *eigenfaces* calcula uma “*face média*”, ou seja, um vetor linha com a média de todos as faces utilizadas durante a fase de treinamento. Após realizado este cálculo é construído uma matriz A onde a linha i da matriz representa o vetor da linha, a partir disso, é realizada o cálculo da matriz de covariância.

As classes são calculadas pela média dos resultados da representação *eigenfaces* sobre um pequeno número de imagens faciais de cada indivíduo. A fase é classificada como pertencente a classe x quando o ϵ_x mínimo é inferior a um limiar definido. Caso contrário, a fase pode ser classificada como “desconhecida” (TURK; PENTLAND, 1991).

2.6.3 Algoritmo Fisherfaces

O modelo Fisherfaces proposto por Belhumeur, Hespanha e Kriegman (1997), baseia-se na Análise de Discriminante Limiar (LDA), desenvolvida para ser um método não sensível à grandes variações de iluminação e expressões faciais. É um método específico à classe, ele trabalha com rótulos, ou seja, uma vez que identificado a face dizendo qual face pertence a pessoa, os mesmos são agrupados por pessoas, cada agrupamento é conhecido como classe. Ele tenta modelar a dispersão dos

pontos visando a maior confiabilidade para se obter a classificação. O LDA busca reduzir de forma otimizada a melhor linha de uma superfície que separa satisfatoriamente as classes. (BELHUMEUR, 1997)

Nos testes realizados por autores de trabalhos correlatos, foi possível observar que o *Fisherfaces* obteve taxas de erros melhores que o *Eigenfaces*, testes baseados na base de dados faciais de Harvard e de Yale. Apesar do método ser insensitivo à grande variação de iluminação e expressões faciais, ele não tem a proposta de lidar com as variações de pose, o que pode ser um fator relevantemente crucial no reconhecimento facial em ambientes reais.

Primeiramente, o *Fisherfaces* realiza uma projeção do conjunto de imagens em um espaço de baixa dimensionalidade utilizando a técnica PCA, aplicando posteriormente a técnica LDA para realizar a projeção das imagens faciais em um espaço de dimensionalidade ainda menor. O reconhecimento facial dessa forma é realizado por meio de um subespaço de seus próprios vetores, utilizando a medida de semelhança para comparar com as demais faces projetadas no subespaço (FIGUEREDO, 2011).

De forma resumida, o *Fisherfaces* utiliza PCA para reduzir as dimensionalidades, projetando imagens faciais originais num espaço de menor dimensão, posteriormente utiliza a técnica LDA para procurar a melhor característica discriminante linear no subespaço de PCA. Assim, é possível realizar a classificação de uma nova imagem comparando sua similaridade por meio de testes com as imagens faciais do conjunto pré treinado, determinando assim a quem pertence a face detectada.

Dessa forma, podemos observar a diferença destes três algoritmos. O *Eigenfaces* e o *Fisherfaces* são parecidos, ambos trabalham com as dimensões e vetores da imagem buscando identificar os pontos principais da face no momento da identificação. O LPBH trabalha com matrizes e identificação da vizinhança, mostrando melhor desempenho durante o reconhecimento facial.

O uso de métodos lineares específicos de classe para redução de dimensionalidade, além de classificadores simples no espaço de características reduzido, podendo obter melhores taxas de reconhecimento se comparado com outros métodos como o *eigenfaces* (FIGUEREDO, 2011).

3 Desenvolvimento

O processo de desenvolvimento e treinamento de um algoritmo capaz de detectar e reconhecer um indivíduo por meio de seus padrões e variações requer um entendimento intermediário do funcionamento teórico deste processo. Sendo assim, as considerações realizadas no capítulo 2 auxiliaram no entendimento desta fundamentação necessária para realizar este projeto de pesquisa.

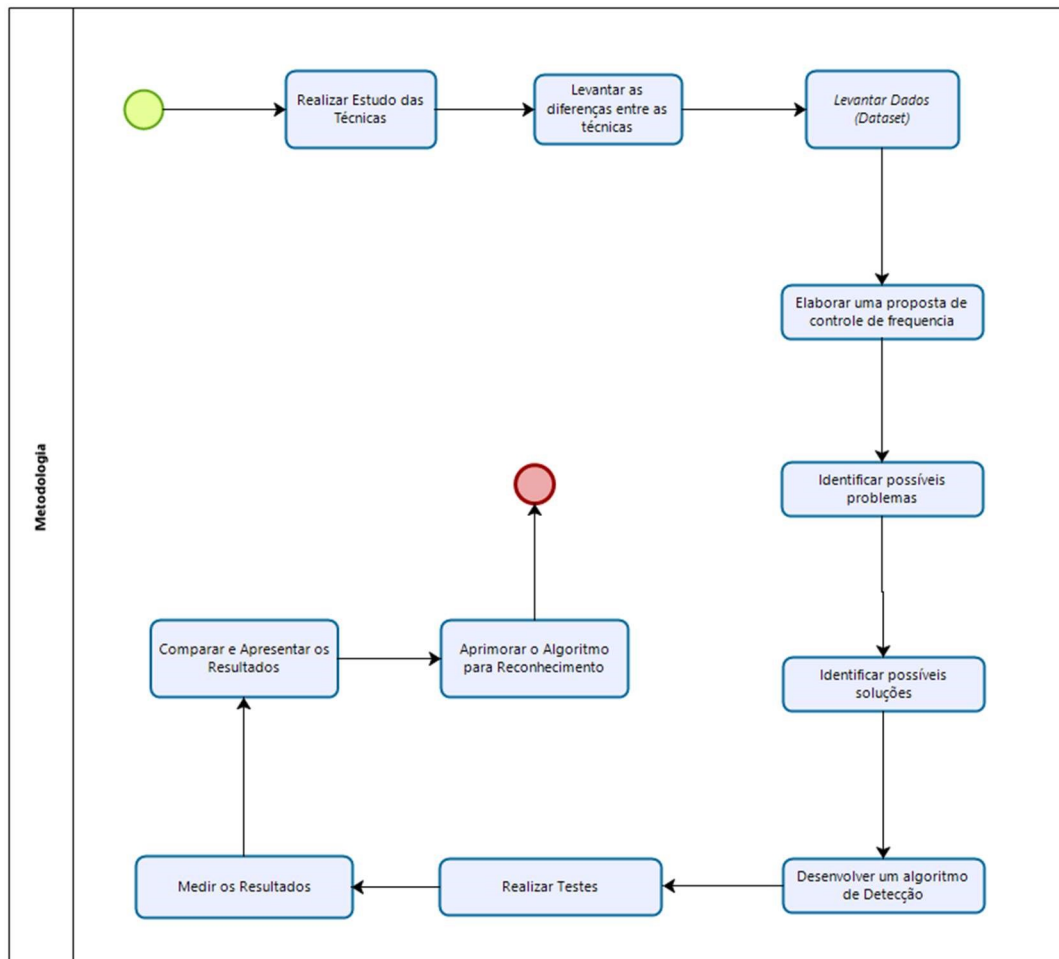
3.1 Processo Metodológico

Para que se possa realizar um projeto com segurança e dar valor a proposta, faz-se necessário realizar um levantamento teórico, ou estudos sobre as técnicas e sistemas atuais, compreendendo de forma mais ampla sobre Reconhecimento Facial, conforme foi apresentado no capítulo 2 deste projeto de pesquisa. Com base neste levantamento, se faz possível realizar a análise das técnicas, validar as diferenças entre os algoritmos hoje existentes, estudar melhorias e elaborar um modelo de proposta para que seja implementado de forma dinâmica e interativa, tendo maior visibilidade, confiabilidade e transparência tanto para o desenvolvedor como para o usuário final.

É necessário levantar ou obter os dados que serão utilizados para realização dos testes para implementação da proposta e do projeto, as imagens, foram adquiridas por meio de solicitação aos acadêmicos do 10º período do Curso de Engenharia de Computação para que pudessem ser testadas, assim como a utilização de *dataset* disponíveis na rede e localizadas para auxiliar na estruturação e treinamento do algoritmo, para que as imagens possam ser estudadas e comparadas por meio do algoritmo. Durante o processo de coleta de imagens foi realizada a assinatura do **Termo de Autorização de uso de imagem** pelos indivíduos envolvidos para que pudessemos realizar os testes deste projeto, sendo assim, todos os indivíduos utilizados durante o processo de testes foram devidamente referenciados no Apêndice A. Para que a nova proposta pudesse ser realizada e valorizada, se faz necessária a realização de estudos direcionados para as técnicas, sistemas e para a instituição que fará utilização de recursos de Inteligência Artificial para melhorar a sua segurança. Realizada a análise foi possível validar as possíveis melhorias que serão propostas em um novo cenário, algoritmo ou sistema. Foi realizado o esboço destas melhorias para que pudesse auxiliar na implementação do algoritmo para que na fase de implementação fosse realizada de forma mais aderente.

Realizado a elaboração da proposta, foi revisto e levantando os possíveis riscos que podem ocorrer na nova proposta, desta forma foi possível levantar juntamente as possíveis soluções para resolver os problemas encontrados. Feito todos os levantamentos necessários, é possível dar início a implementação de um algoritmo que possa de forma confiável, validar dados recebidos seja por uma imagem (foto) ou por imagens de vídeo. De acordo com o andamento de todo o processo, a implementação foi dividida em desenvolvimento e testes direcionados, à medida que o algoritmo foi desenvolvido e à medida que o mesmo foi treinado ele teve de ser “forçado”, ou seja, foram realizados testes de confiabilidade, precisão e autenticidade para que ele possa atender os requisitos necessários em seu desenvolvimento. Finalizando os passos abordados acima, por meio dos testes e análise, foi possível apresentarmos os resultados do estudo realizado. Com os resultados podemos apresentar as melhorias e as funcionalidades implementadas e como foram implementadas para atender as necessidades de melhoria de controle de frequência proposto neste projeto. A figura 10 ilustra a metodologia proposta para este trabalho.

Figura 10: Metodologia do Trabalho de Conclusão de Curso. Fonte: AMORIM, Thais Tavares




3.2 Coleta de Imagens

Para realizar o treinamento fez-se necessário primeiramente coletar as imagens que foram utilizadas para elaborar o treinamento dos algoritmos, para isso, foi coletada as imagens dentro do âmbito do Centro Universitário de Anápolis de alguns dos acadêmicos do 10º Período de Engenharia de Computação, os quais participarão do projeto piloto de testes desta proposta.⁴

Para o desenvolvimento deste projeto, foram utilizadas as técnicas propostas por (VIOLA; JONES, 2001) devido a serem bastante utilizadas para resolução de problemas que envolve o reconhecimento de padrões a partir de imagens. O *haarcascade* que pode ser encontrado na biblioteca *OpenCV*, é um algoritmo de aprendizado baseado em *AdaBoost*⁵, que seleciona um pequeno número de características visuais críticas de uma determinada imagem e as utiliza para a etapa de detecção e classificação de objetos. Na linha 1 a 4 do Código do Apêndice B realizamos as importações das bibliotecas necessárias e os classificadores utilizados nesta análise. Neste caso, iremos utilizar inicialmente apenas o classificador *haarcascade frontalface* como apresentado no capítulo 2 deste projeto é um método baseado em características onde estão os parâmetros necessários para que uma face seja detectada em um vídeo ou imagem.

Na linha 16 de Código de captura é onde realizamos a conversão das imagens em escala de cinza pra que possa ser realizado o treinamento, realizada a conversão da imagem é elaborada um *for* aonde informamos os parâmetros do retângulo que irá demarcar a face detectada conforme apresentado na Figura 11.

Figura 11: Demarcações do Retângulo ao Detectar uma Face




⁴ Apêndice A apresentam-se as autorizações de utilização de imagens assinadas pelos atores deste projeto, conforme informado na sessão 3.1 do Capítulo 3 deste projeto.

⁵ *AdaBoost*, algoritmo de *boosting* é uma técnica de aprendizado de máquina que combina diversos classificadores *fracos* com o objetivo de melhorar a acurácia geral.

De acordo com os parâmetros pré informados no classificador o algoritmo localiza a face na imagem e cria um retângulo em volta do objeto que deverá ser identificado, neste caso, a face do indivíduo.

Utilizamos um conjunto de amostras contendo 135 imagens positivas, estas imagens foram geradas a partir de 25 imagens capturadas de cada indivíduo. A linha 30 foi implementado uma condição de parada para realizar o registro de cada imagem, sendo essas imagens variadas (Expressões variadas) para melhor preparação do algoritmo. Desta forma foi possível criarmos nosso próprio *dataset*⁶ para realizarmos o treinamento dos modelos de algoritmos utilizados para este estudo de caso. Como falado anteriormente nesta seção, durante o processo de captura de imagens o algoritmo já realiza a conversão da imagem para escalas de cinza, por esse motivo as imagens salvas em nosso *dataset* serão apresentadas já convertidas e com os ID's estipulados de forma incremental pelo algoritmo conforme padronizado na linha 34 do nosso código de captura. As Figuras 12 e 13 é a representação de algumas das imagens coletadas dos indivíduos durante o processo de coleta, não estando presente todas as amostras.

Figura 12: Pessoas 1 e 2 convertidas em escala de cinza.



⁶ *Dataset* é uma coleção de dados normalmente tabulados por elementos (ou indivíduos) que indicam várias características.

As imagens apresentadas na Figura 12, foram as primeiras amostras de imagens realizadas para o treinamento do algoritmo, com a pessoa 1 e com a pessoa 2 foram realizadas 25 capturas com diversas variações para que o algoritmo pudesse capturar o máximo de informações possíveis de cada indivíduo, como por exemplo, foram registradas imagens com expressões faciais diferentes e até mesmo com a utilização de óculos para que o algoritmo consiga assimilar estas informações. Quanto maior o número de imagens for coletado melhores serão os resultados que poderão ser alcançados, sendo assim a Figura 13 apresenta a pessoa 3, 4 e 5 com variações nas expressões para que o algoritmo possa aprender mais sobre as características de cada pessoa.

Figura 13: Pessoa 3, 4 e 5 convertidas em Escala de Cinza



Embora quanto maior o número de imagens melhores são nossos resultados, para execução deste projeto foi utilizado um cenário menor, aonde fez-se possível utilizar um *dataset* pequeno para realizar o treinamento das imagens, buscando assim

melhorar o entendimento dos autores sobre o processo e validar se de fato os resultados seriam satisfatórios para a análise realizada.

3.3 Treinamento do Algoritmo

Realizada a coleta das imagens, fez-se possível darmos início a fase de treinamento dos modelos Eigenfaces, Fisherfaces e LBPH com as imagens que foram capturadas na sessão 3.2 deste capítulo. Nas linhas 5, 6 e 7 do código presente no apêndice C informamos as importações dos algoritmos que utilizaremos, onde podemos definir os parâmetros de testes nos próximos passos.

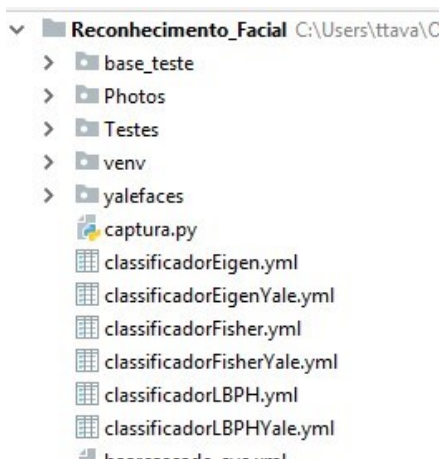
Na linha 10 foi indicado o diretório onde estão salvas as imagens que foram utilizadas neste treinamento, onde o algoritmo irá pegar as imagens transformadas em escala de cinza, conforme apresentado na linha 15. Durante o processo de captura foi dado um identificador (ID) para cada imagem e durante a fase de treinamento utilizamos para identificar os indivíduos.

Figura 14: Array de ID's, matriz de similaridade gerada

```
[array([[31, 30, 28, ..., 23, 23, 23],
       [31, 29, 27, ..., 26, 27, 28],
       [28, 27, 26, ..., 26, 27, 29],
       ...,
       [18, 16, 13, ..., 1, 1, 1],
       [18, 16, 14, ..., 2, 2, 2],
       [17, 15, 14, ..., 4, 3, 3]], dtype=uint8), array([[ 2,  2,  2, ..., 15, 14, 12],
       [ 2,  2,  2, ..., 17, 15, 15],
       [ 2,  2,  2, ..., 16, 15, 14],
```

Nas linhas 30 a 37 apresenta os arquivos classificadores gerados com as informações apresentadas na Figura 14 e no apêndice C para que durante a execução de cada um dos algoritmos estas matrizes pudessem ser utilizadas para realizar o reconhecimento dos indivíduos.

Figura 15: Classificadores gerados na fase de treinamento



Na Figura 15 são apresentados os classificadores que foram utilizados nos códigos de cada modelo de algoritmos, os mesmos contêm as informações necessárias para realizar a identificação do indivíduo.

3.4 Reconhecedor Eigenfaces

Como já visto anteriormente o eigenfaces utiliza imagens de treinamento para aprender um modelo de face, ou seja, ele cria vetores através da técnica PCA, que é responsável pelo treinamento da base de dados e transformar as informações visuais em vetores, que representam pontos marcados na imagem, estes pontos podem utilizados para detecção de padrões nas faces humanas.

O *eigenfaces* com base na imagem original capturada para treinamento, gera algumas imagens fantasmas(*eigenfaces*) que são as principais características do indivíduo capturadas. Com base nessas imagens o algoritmo faz uma combinação linear onde ele soma a imagem submetida com a imagem média gerada após a verificação das imagens que estão disponíveis no Banco de Imagens, conforme apresenta a figura 16.

Figura 16: Representação de Imagens Eigenfaces



Para realizar o reconhecimento facial utilizando o *eigenfaces*, foi desenvolvido um código para que após a detecção pudesse informar quem é o indivíduo que é detectada na imagem ou vídeo. O código utilizado para realizar o reconhecimento com base no eigenfaces está no apêndice D deste projeto, aonde na linha 4 é realizada a

chamada da função do *Eigenfaces Recognizer* onde armazenaremos as informações que são geradas após o treinamento de nosso algoritmo.

Na linha 5 informamos o caminho do nosso reconhecedor, o arquivo de classificação que é gerado após o treinamento da captura e armazena as matrizes de similaridade identificadas durante o processo de treinamento de cada indivíduo para que seja possível a identificação das faces após o treinamento. As linhas 16 a 35 é realizada a verificação da identidade do indivíduo o qual a câmera capturou a imagem, no código de captura, na linha 34 informamos a nomenclatura a qual deverá ser salvo o arquivo em nosso banco de imagens, na linha 19 do código de reconhecimento eigenfaces realizamos a chamada destes ID's que são adicionados de forma incremental no momento de salvar a imagem e realizamos a chamada da função do nosso reconhecedor que é nosso classificador informado na linha 5 do código onde estão as informações aprendidas da imagem.

Para fins de testes, das linhas 20 a 32 são as representações das pessoas 1,2,3,4 e 5, no caso de uma base de dados grande, aonde é necessário a detecção de vários indivíduos é necessário realizar uma lista com todos os ID's e nomes dos indivíduos que irão utilizar, nesta fase como apenas usaremos 5 pessoas para testes as informações foram incluídas em uma estrutura de repetição (*if* , *elif* e *else*) onde informamos o nome do indivíduo de acordo com seu ID. Sendo assim, se o ID identificado for igual a 1 ele será apresentado no primeiro nome (*if*), se o ID for igual a 2 por exemplo será apresentado o segundo nome (*elif*) e se não for identificado como nenhum dos indivíduos, ele será dado como desconhecido (*else*) conforme representado das linhas 20 a 32 do Apêndice D.

A Figura 17 representa a tentativa de reconhecimento utilizando o *eigenfaces*, quando realizamos o teste de detecção de face e reconhecimento foi possível observar que algumas variações de luminosidades ou de posições podem dificultar a identificação dos usuários, neste caso, o algoritmo não conseguiu identificar os indivíduos 1 e 5 tratando os mesmos como desconhecidos.

Figura 17: 1ª Tentativa de Reconhecimento com Eigenfaces




Para realizar a classificação das imagens o algoritmo projeta as imagens no espaço de faces, realiza a extração dos componentes principais do indivíduo, realiza o cálculo da distância entre a nova face e as faces de treinamento utilizando KNN⁷, e busca nas imagens de treinamento pela imagem semelhante daquele indivíduo que está em captura.

Desta forma o *eigenfaces* olha para todas as imagens de todos os indivíduos de uma vez e busca encontrar os componentes principais de todas as imagens, ele não foca apenas nas características que distinguem um indivíduo do outro, mas sim a face como um todo. O PCA trabalha com variações, ele observa todas as variações e faz a combinação de todas para gerar a imagem média daquele indivíduo. Neste algoritmo, um fator muito importante é a luminosidade, um ambiente com pouca luminosidade pode causar uma distância mais longa, fazendo com que o algoritmo não reconheça sua face, ou tenha dificuldades de informar quem é o indivíduo.

Na Figura 18 podemos observar que após variar a posição dos indivíduos, aproximarmos um pouco mais para realizar a captura, o algoritmo já consegue realizar essa identificação de maneira correta, informando assim quem são os indivíduos ali presentes na imagem.

⁷ KNN (K – Nearest Neighbors) é um algoritmo mais simples em Machine Learning utilizado em grande escala para resolver problemas de classificação e regressão

Figura 18: 2ª Tentativa de Reconhecimento Facial com eigenfaces



3.5 Reconhecedor Fisherfaces

Diferente do *Eigenfaces* o reconhecedor *Fisherfaces* utiliza o método LDA (*Linear Discriminant Analysis*) que trabalha com a redução das dimensões da imagem, seu objetivo não é focar nas variações como vimos no caso do PCA, mas sim buscar por classes focando nas características relevantes da imagem. O *Fisherfaces* é uma melhoria do algoritmo *eigenfaces*, ele realiza a extração das informações ou características de forma separada, ou seja, a iluminação não afeta a outra imagem.

Neste modelo continuaremos trabalhando com a mesma estrutura do algoritmo apresentado para o *Eigenfaces*, porém, os parâmetros adicionados para atender o modelo do *fisherfaces*. Na linha 5 do código do apêndice E pegamos as informações do Classificador que foi criado durante o processo de treinamento para *Fisherfaces*.

Figura 19: Tentativas de identificação utilizando Fisherfaces



Podemos observar que como representado na Figura 19 a imagem que o algoritmo detecta traz a informação do indivíduo de acordo com o que foi aprendido durante o processo de treinamento, nesta fase de treinamento as informações, o nome dos indivíduos foram inseridas no código por meio de uma estrutura de repetição apenas para realização de testes, caso esta informação não fosse incluída no código ao representar a identificação do indivíduo seria representado apenas o ID dado no início da captura, como visto na sessão 3.2, caso tivéssemos uma base de dados maior seria necessário criar uma lista contendo todos os ID's e nomes para que o algoritmo fizesse a busca e trouxesse a informação do usuário.

Outro fator extremamente importante é a variação de pose e/ou a oclusão parcial da imagem pode prejudicar a forma que o algoritmo transmita o resultado do reconhecimento, como vimos na Figura 19, devido a variação de luminosidade o algoritmo acaba identificado o indivíduo 3 como o mesmo nome do indivíduo 1.

Figura 20: Tentativa de Reconhecimento com Fisherfaces



Após melhorar a luminosidade da imagem, observamos que o algoritmo consegue identificar claramente o indivíduo 3, fazendo isto da forma correta, conforme vimos na figura 20.

3.6 Reconhedor LPBH

O LBPH se mostrou bastante robusto em comparação aos demais algoritmos apresentados na sessão 3.4 e 3.5 deste capítulo. Ele utiliza parâmetros de validação de características que otimizam sua busca e visualização das características relevantes e importantes. O código do apêndice F segue o mesmo sentido dos demais

códigos apresentados, porém o mesmo realiza parametrizações para que suas validações sejam mais eficientes.


Na linha 4 e 5 do apêndice F definimos o classificador LBPH que é desenvolvido durante o treinamento do algoritmo para que seja realizado, onde estão as informações que foram geradas após a comparação das imagens capturadas no processo descrito no item 3.2 deste capítulo. Da mesma forma dos demais algoritmos o valor de confiança é solicitado e apresentando na linha 35 deste código.

Figura 21: Tentativa de Treinamento Algoritmo LBPH



Como podemos observar na figura 21, uma imagem que não consta no banco de dados deverá ser tratada como desconhecida, não sendo assim reconhecida. O LBPH apresenta uma vantagem com relação as transformações monotônicas em escala de cinza, permitindo assim a identificação de bordas nas imagens. Embora ainda neste modelo uma variação de pose, ou oclusão da face pode influenciar na identificação, o mesmo apresenta melhores resultados que os demais algoritmos.

Figura 22: Tentativa de Reconhecimento com LPBH



Podemos observar na Figura 22 que a variação de pose do indivíduo 2 não permitiu que o algoritmo identificasse sua face e assim não sendo possível realizar a identificação do mesmo conforme realizamos com os demais indivíduos. Na Figura 23 podemos observar que com uma pequena variação o algoritmo já consegue identificar o usuário e trazer as informações do mesmo.

Figura 23: Identificação utilizando LPBH



3.7 Avaliação dos Algoritmos

Neste passo vamos realizar a avaliação dos algoritmos que foram exemplificados nos itens 3.4 a 3.6, neste projeto optou-se por trabalhar a quantidade de acertos e a melhor distância que os algoritmos retornam para que possamos conseguir chegar em um percentual de acertos aceitável para nosso projeto.

Na base de treinamento, foram coletadas imagens durante o processo de captura apresentado no item 3.2 deste capítulo, nesta base nos temos 130 amostras de imagens treinadas pelo algoritmo, sendo 25 imagens de treinamento para cada pessoa, possuindo as variações de posição ou expressão facial para melhor identificar o indivíduo. Nesta base de treinamento nós temos 5 indivíduos diferentes para realizar o treinamento.

Para realizarmos a avaliação usaremos as amostras salvas na base teste para realizar a verificação de acertos e melhor distância com relação as imagens, lembrando que as imagens precisam ser diferentes das coletadas na fase de captura para que possamos ter melhores resultados de desempenho, sendo assim, temos 30 amostras de teste, sendo 6 amostras de cada indivíduo conforme representado na Figura 24.

Figura 24: Imagens de Teste para Reconhecimento Facial



Temos o arquivo treinamento que já trabalhamos na sessão 3.3 deste capítulo onde foram gerados os classificadores que serão a base dos nossos testes de identificação.

Na linha 4 do apêndice C realizamos a importação da biblioteca PIL *import image* necessária para trabalharmos com imagens em disco. Nas linhas 6,7 e 8 foram gerados os classificadores como visto anteriormente, realizando a busca da pasta na linha 11 que estão as imagens de treinamento, nosso diretório '*Photos*' e na linha 15 realizamos a conversão das imagens em escala de cinza.

Para iniciarmos a avaliação dos algoritmos usaremos o código do apêndice G, aonde precisamos detectar nas imagens de testes primeiramente a face assim como realizamos nos outros itens, para que assim possamos avaliar se aquela imagem submetida ao algoritmo pertence a base de dados que geramos nos itens anteriores. Na linha 8, 10 e 12 nos vemos o resultado dos Classificadores gerados durante o processo de treinamento. Na linha 16 temos a variável de total de acertos, a linha 17 é apresentado o percentual de acerto do algoritmo e na linha 18 o valor total da confiança ou a menor distância para dissermos o quão confiável cada algoritmo é, levando em conta que quanto menor o valor da distância mais confiável é a detecção realizada por ele.

Na linha 20 repetimos a mesma chamada realizada no treinamento para carregarmos as imagens que estão em nossa base de testes e converter em escala de cinza. Da linha 21 a 29 informamos os parâmetros para a detecção de face de cada uma das imagens que estão na base de testes para garantir que todas as imagens de testes estão sendo detectadas pelo algoritmo.

Figura 25: Faces de Teste Detectadas

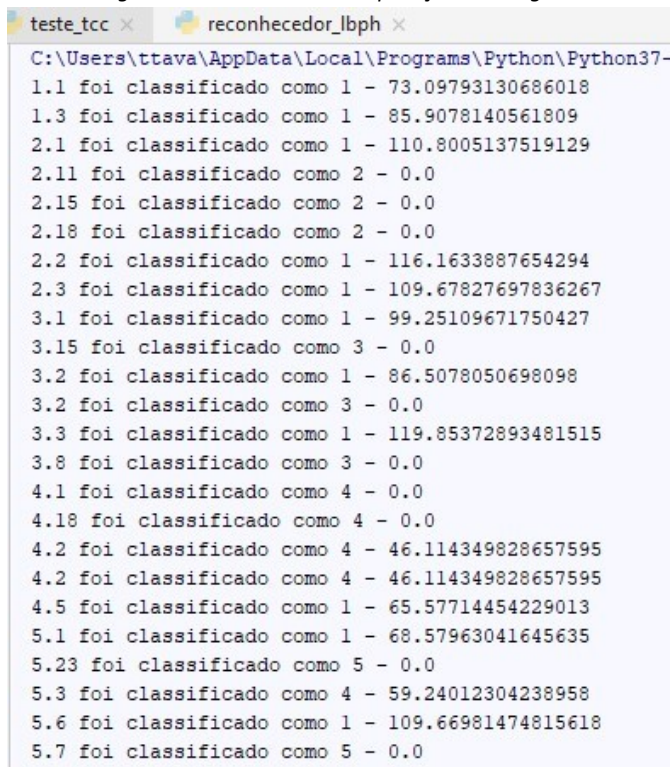


A figura 25 apresenta o exemplo de imagens de testes convertidas em escala de cinza que foram detectadas pelo algoritmo de teste para avaliação dos algoritmos. Caso para alguma não tivesse sido possível realizar a captura da imagem teríamos que rever os parâmetros informados no código para realizar este procedimento.

Na linha 25 nós realizamos a comparação do ID previsto pelo classificador que foi gerado durante o processo de treinamento com o ID que possuímos atribuído para cada imagem do nosso banco de dados.

Na linha 27 colocamos um print para realizar a impressão com o resultado da comparação da classe, por exemplo, classe 1.1 foi identificada como classe 1 ou classe 2.1 foi classificado como classe 1 conforme representado na Figura 26.

Figura 26: Resultado da comparação de imagens



```
teste_tcc x reconhecedor_lbph x
C:\Users\ttava\AppData\Local\Programs\Python\Python37-
1.1 foi classificado como 1 - 73.09793130686018
1.3 foi classificado como 1 - 85.9078140561809
2.1 foi classificado como 1 - 110.8005137519129
2.11 foi classificado como 2 - 0.0
2.15 foi classificado como 2 - 0.0
2.18 foi classificado como 2 - 0.0
2.2 foi classificado como 1 - 116.1633887654294
2.3 foi classificado como 1 - 109.67827697836267
3.1 foi classificado como 1 - 99.25109671750427
3.15 foi classificado como 3 - 0.0
3.2 foi classificado como 1 - 86.5078050698098
3.2 foi classificado como 3 - 0.0
3.3 foi classificado como 1 - 119.85372893481515
3.8 foi classificado como 3 - 0.0
4.1 foi classificado como 4 - 0.0
4.18 foi classificado como 4 - 0.0
4.2 foi classificado como 4 - 46.114349828657595
4.2 foi classificado como 4 - 46.114349828657595
4.5 foi classificado como 1 - 65.57714454229013
5.1 foi classificado como 1 - 68.57963041645635
5.23 foi classificado como 5 - 0.0
5.3 foi classificado como 4 - 59.24012304238958
5.6 foi classificado como 1 - 109.66981474815618
5.7 foi classificado como 5 - 0.0
```

Foi possível observar na figura 26 que as imagens foram classificadas de acordo com o treinamento, então podemos observar que ele retorna o valor da distância de cada imagem gerada, as imagens que estão com o valor 0 (Zerado) é porque essas imagens são idênticas as que temos na base de treinamento, ou seja, a sua distância é a menor possível pois elas são iguais. O que temos que tomar cuidado para que não tenhamos imagens iguais em nossa base de testes para que possamos avaliar melhor o desempenho do algoritmo, na figura 27 podemos ver que o algoritmo conseguiu classificar corretamente as imagens e como não possuímos imagens idênticas observamos que os valores de distância variam e o algoritmo consegue classificar as imagens de acordo com sua similaridade.

Figura 27: Avaliação do Algoritmo - Classificação

```

C:\Users\ttava\AppData\Local\Programs\Python\Python37-
1.1 foi classificado como 1 - 73.09793130686018
1.3 foi classificado como 1 - 86.13236099294899
2.1 foi classificado como 1 - 110.8005137519129
2.11 foi classificado como 2 - 20.884589541130918
2.15 foi classificado como 2 - 25.178916205932502
2.18 foi classificado como 2 - 20.247085434470716
2.2 foi classificado como 1 - 116.1633887654294
2.3 foi classificado como 1 - 109.67827697836267
3.1 foi classificado como 1 - 101.37088337053937
3.15 foi classificado como 3 - 25.120076096416522
3.2 foi classificado como 4 - 89.05683954917764
3.2 foi classificado como 3 - 18.45865669200767
3.3 foi classificado como 1 - 122.01376168401348
3.8 foi classificado como 3 - 23.022181614715475
4.1 foi classificado como 4 - 26.919427959493298
4.18 foi classificado como 4 - 23.210831976770884
4.2 foi classificado como 4 - 46.114349828657595
4.2 foi classificado como 4 - 46.114349828657595
4.5 foi classificado como 4 - 65.90258322459864
5.1 foi classificado como 4 - 69.8230713808237
5.23 foi classificado como 5 - 27.591066696064843
5.3 foi classificado como 4 - 59.24012304238958
5.6 foi classificado como 1 - 109.66981474815618
5.7 foi classificado como 5 - 20.97467112050196

```

Na figura 26 e 27 conseguimos verificar os acertos e erros que tivemos durante a avaliação do algoritmo. Sendo assim nos testes iniciais, com as imagens de testes que temos conseguimos alcançar 54% de acertos.

Para avaliação dos algoritmos nós realizamos as alterações de parâmetros antes de realizar o treinamento dos algoritmos para verificar o desempenho dos mesmos. Para o Eigenfaces, iniciamos com o padrão e o mesmo retornou um percentual de acerto de 78% das imagens em nossa base de testes, porém o valor da distância ficou em 5388,98, ou seja, embora o percentual de acerto tenha sido alto, o valor de distância entre as imagens foi alto, entendendo assim que embora o algoritmo tenha tido uma taxa percentual alta de acerto, ele é menos confiável em sua assertiva. O melhor resultado encontrado para o eigenfaces foi com os parâmetros de número de componentes igual a 50 e o *thresholds* com valor de 7000 onde obtivemos 50% de acerto porém a distância encontrada foi menor, sendo de 2241,33 apresentando assim um melhor resultado em relação a confiança de que a imagem de fato é pertinente aquele indivíduo.

Com o Fisherfaces realizamos as mesmas configurações de parâmetros e de início com o padrão retornou o percentual de 80% das imagens da base de testes, porém o valor do erro ficou em 1645,89. O melhor resultado durante o processo de avaliação foi com os parâmetros de : número de componentes igual a 7 e *thresholds* igual a 8000 onde obtivemos 90% de acerto porém com a distância de 872,445 um valor ainda alto para veracidade das informações devido a esperarmos o valor mais próximo de 0 possível, durante os mesmos testes foram parametrizados número de componentes igual a 3 e *thresholds* igual a 2000 e obtivemos um resultado de 76% de acerto e distância de 466,203 com base na precisão de que a imagem de fato é daquele individuo este pode ser considerado o mesmo resultado.

Com o LPBH inicialmente realizamos testes com as parametrizações padrão e obtivemos um resultado de 66% de acertos e valor de distância de 10,69. O melhor cenário durante a realização de testes foram das parametrizações de *radius*⁸ igual a 2, *neighbors*⁹ igual a 2, *grid_x*¹⁰ e *grid_y*¹¹ igual a 7 e por fim *thresholds* igual a 50 onde obtivemos um percentual de 63% de acertos e a distância de 0,77. Sendo assim, em relação a confiança este foi o melhor resultado encontrado pelo algoritmo.

⁸ *Radius* é usado para construir o padrão binário local circular e representado o raio ao redor do pixel central. Geralmente definido como 1.

⁹ *Neighbors* é o número de pontos de amostra para construir o padrão binário local circular. Obs. Quanto mais pontos forem inseridos, maior será o custo computacional. Geralmente definido como 8.

¹⁰ *Grid_X* é o número de células na direção horizontal. Quanto mais células, quanto mais fina a grade, maior a dimensionalidade do vetor de recursos resultante. Geralmente definido como 8

¹¹ *Grid_Y* é o número de células na direção vertical. Quanto mais células, quanto mais fina a grade, maior a dimensionalidade do vetor de recursos resultante. Geralmente definido como 8

4 Discussão de Resultados

Na capítulo 3 foram apresentados alguns experimentos realizados envolvendo o valor de confiança ou a menor distância entre duas imagens e o percentual de acertos dos algoritmos. Como entendemos o valor da confiança pode ser utilizado como que um “validador” para realizar o reconhecimento em ambientes reais, onde não é viável a conferência de forma manual de todas as imagens detectadas pelo sistema.

Como proposto no capítulo anterior, o valor desta confiança para os métodos *eigenfaces*, *fisherfaces* e *LPBH* são calculados diretamente pela biblioteca do OpenCV, de acordo com uma medida de distância. É possível notar que nos métodos quanto mais próximo do zero for o valor da distância maior é a chance de o resultado do classificador estar correto, sendo assim, para o reconhecimento facial ser considerado correto ele deve estar abaixo do limite linear pré-definido.

No entanto, assim como vários outros métodos de classificação, não há um valor ideal para parametrização do limiar, desta forma faz-se necessário realizar testes, ou experimentos alterando estes parâmetros até encontrar o que melhor se adapte ao ambiente real que a proposta será implementada e assim possa nos auxiliar a alcançar os objetivo deste projeto de pesquisa, realizar o controle de frequência acadêmica por meio de reconhecimento facial.

Tabela 1: Variações de Parâmetros e Resultados Eigenfaces

Eigenfaces		
Acerto	Confiança	Parametro
78%	5388,98	Padrão
50%	2241,33	50, 7000
53%	2556,59	50, 8000
60%	2976,57	40, 8000

Como podemos ver na tabela 1 de acordo com as variações dos parâmetros podemos possuir valores de distância melhores, a taxa de acerto nem sempre será a maior se formos considerar a confiança como indicador principal para nossa comparação. Como falamos anteriormente, quanto mais próximo do zero o valor da confiança ou menor a distância se apresentar, maiores são as chances de confiabilidade da informação que da imagem ou do reconhecimento do indivíduo.

Tabela 2: Resultados dos Parâmetros Fisherfaces

Fisherfaces		
Acerto	Confiança	Parametro
80%	1645,89	Padrão
76%	466,203	3, 2000
86%	659,756	5, 5000
90%	872,445	7, 800

A tabela 2 apresenta os resultados obtidos pelo modelo fisherfaces, em comparação com o eigenfaces obtivemos resultados bem melhores em relação a variação de acerto, ou a quantidade de imagens reconhecidas por este modelo, porém podemos observar que nosso valor de distância está mais alto, embora percentualmente o algoritmo tenha acertado uma quantidade maior de faces, a sua confiança ainda é baixa.

Tabela 3: Resultados dos Parâmetros LPBH

LBPH		
Acerto	Confiança	Parametro
66%	10,69	Padrão
63%	0,77	2,2,7,7,50
66%	5,73	3, 3, 9, 9,60
63%	2,80	2, 2, 10, 10, 40

A tabela 3 apresenta os resultados obtidos pelo modelo LBPH, em comparação com os demais algoritmos eigenfaces e fisherfaces, o LBPH é mais robusto durante o processo de confiança da imagem, se observamos os percentuais de acerto deste algoritmo são menores, porém, seu valor de distância / confiança é bem mais assertivo do que os demais apresentados na tabela 1 e 2.

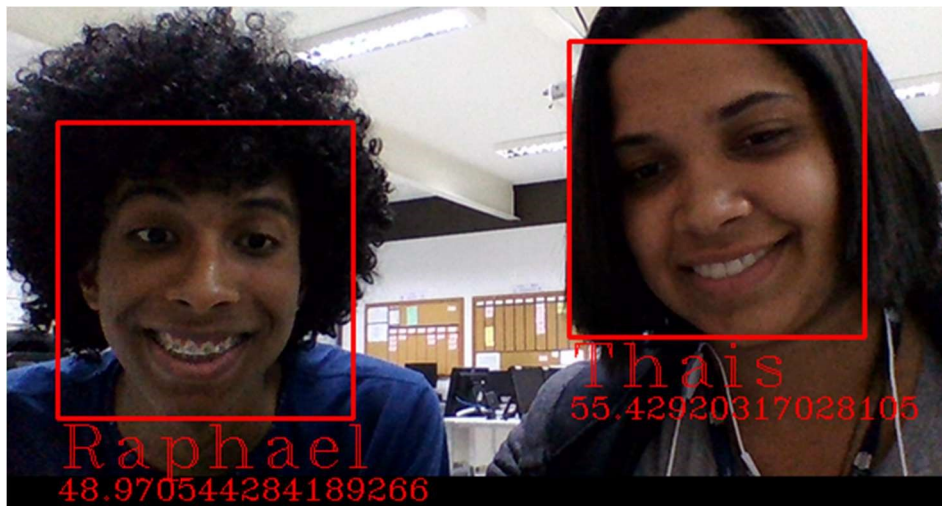
Sendo assim, é possível notar que de acordo com os padrões estabelecidos para cada algoritmos eles iram retornar o melhor resultado possível de acordo com o ambiente trabalhado. Em relação a detecção das faces, durante o processo de treinamento, podemos observar que os algoritmos eigenfaces e fisherfaces em alguns casos tiveram dificuldade de identificação da imagem, não capturando a face do indivíduo conforme apresentado na Figura 28.

Figura 28: Tentativa de Detecção de Face já existente na base de dados



Observamos que o algoritmo consegue realizar a identificação do indivíduo 1, porém, nem mesmo realiza a captura da imagem do indivíduo 4. Porém, com o LBPH tivemos resultados mais precisos e rápidos como apresentado a figura 29.

Figura 29: Identificação de Indivíduo com LPBH




Os valores apresentados abaixo dos nomes dos usuários são os valores de distância, ou seja, a confiança ou precisão de que de fato aquela imagem pertence a um indivíduo que está em nossa base de dados e que nosso algoritmo treinou e aprendeu suas características.

Ainda durante os testes, quando tentávamos identificar mais de 2 ou 3 indivíduos os algoritmos possuíam dificuldade de identificar os mesmos, porém, no

LPBH tivemos uma quantidade de acerto mais referente a detecção e identificação de múltiplos indivíduos em uma única captura conforme apresentado na figura 30.

Figura 30: Identificação de múltiplos usuários LPBH



Observamos que o valor de distância destes indivíduos está caracterizado como que com 54,10 em alguns casos, 57,86 de confiança de que de fato aquela face pertence respectivamente aos indivíduos 1, 2, 3 e 5.

Levando em consideração os testes realizados e as técnicas estudadas a tabela 4 apresenta uma breve apresentação da comparação dos pontos positivos e negativos encontrados durante a avaliação dos algoritmos.

Tabela 4: Pontos Positivos e Negativos.

Algoritmo	Pontos	Descrição
<i>Eigenfaces</i>	Positivos	Insensitivo à pouca variação de iluminação. Embora seja um dos métodos mais antigos e conhecido da área de reconhecimento
	Negativos	A variação de pose e a oclusão podem prejudicar o resultado do reconhecimento.

<i>Fisherfaces</i>	Positivos	Insensitivo a certa variação de iluminação e expressões faciais. Com base no estudo realizado teve melhores resultados que o Eigenfaces.
	Negativos	A variação de pose e a oclusão parcial podem prejudicar de forma significativa o resultado do reconhecimento
<i>Local Binary Patterns (LBPH)</i>	Positivos	Robusto em relação as transformações monotônicas em escala de cinza. Permitindo identificar bordas.
	Negativos	A variação de pose e a oclusão parcial podem prejudicar de forma significativa o resultado do reconhecimento

De forma a apresentar de forma mais clara os resultados obtidos a Tabela 5 apresenta os resultados Padrão de cada algoritmo juntamente com os melhores resultados para cada um deles em quantidade de acertos e melhor distância.

Tabela 5: Comparativo de Resultados entre Algoritmos

Algoritmo	<i>Eigenfaces</i>	<i>Fisherfaces</i>	<i>LBPH</i>
PercentualAcerto	78% de acerto, porém com valor de distância alta 5388,98	90% de acerto, porém com valor de distância alta 872,445	66% de acerto, porém com valor de distância alta 10,69
MelhorDistância	Melhor distância 2976,57 , porém com percentualAcerto de 60%	Melhor distância 466,203 , porém com percentualAcerto de 60%	Melhor distância 0,77 , porém com percentualAcerto de 60%

Com base nessas considerações, pelos resultados obtidos e pelos estudos correlatos encontrados podemos observar que o LBPH de fato é mais robusto e retorna resultados mais precisos em relação ao valor de distância de cada imagem sendo entre os algoritmos testados o mais confiável durante o processo de identificação, sendo possível, garantir maior confiabilidade de resultado para a identificação dos indivíduos.

5 Conclusão

Com o auxílio dos trabalhos correlatos e os estudos realizados para desenvolvimento desta pesquisa foi possível analisar mais a fundo os algoritmos *eigenfaces*, *fisherfaces* e *LPBH* e de fato comprovar o funcionamento e os resultados destes métodos.

O valor de confiança como falamos anteriormente corresponde a medida da distância entre a imagem facial submetida e a imagem facial que é classificada, ou seja, que foi coletada para nossa base de dados e utilizada para realizar o treinamento do algoritmo. Dessa forma a medida de confiança é a melhor maneira de compararmos se a imagem foi classificada e/ou reconhecida da forma correta ou não.

De acordo com os experimentos realizados, as taxas de reconhecimento facial foram baixas, porém, isto ocorre devido à baixa qualidade das imagens de teste. Em ambientes controlados é possível obtermos uma taxa de reconhecimento facial mais alta, normalmente quando as imagens de treinamento e de teste possuem boa qualidade, e em lugares onde é possível controlar mesmo que de forma parcial a luminosidade e a orientação da pose do indivíduo.

Para PRADO (2017), o algoritmo *LBPH* apresentou melhor desempenho durante os testes devido o mesmo ser mais robusto e o atendimento de possíveis variações. Durante o estudo realizado neste projeto de pesquisa, embora o *Fisherfaces* tenha se destacado no percentual de acertos durante o processo de identificação com a base de testes, observamos que em relação a confiabilidade e precisão de detecção e identificação o *LBPH* se mostrou mais preciso que os demais algoritmos, embora a taxa de acerto de identificação tenha sido menor que as demais, a taxa de distância foi a mais próxima de zero mostrando assim que os resultados tinham uma taxa maior de confiança, ou seja, certeza que a identificação estava correta, como vimos no capítulo 4 chegamos a taxa de distância de 0,77 durante os testes de identificação.

Observamos que a taxa de desempenho do *LPBH* obteve os melhores resultados quando utilizados com parâmetros padrões da biblioteca do OpenCV no ambiente de teste proposto neste projeto de pesquisa. O *eigenfaces* apresentou um desempenho inferior durante o processo de avaliação dos algoritmos tornando-se dispensável de utilização para este projeto.

O desenvolvimento deste projeto constituiu uma experiência importante possibilitando o aprimoramento e conhecimento sobre a área de detecção e reconhecimento facial, seja com perspectiva profissional ou até mesmo pessoal.

Inicialmente foram encontradas algumas dificuldades para entender o procedimento de detecção e identificação das faces, fazendo-se necessário primeiro o aprendizado de alguns métodos de desenvolvimento para conseguir entender os códigos existentes e realizar o desenvolvimento dos códigos deste projeto. Com este aprendizado foi possível entregar mais resultados durante o processo de estudo e avaliação dos resultados para este projeto.

Conclui-se desta forma que os resultados obtidos neste projeto não teriam sido suficientes para realizar o monitoramento de frequência em sala de aula em um ambiente acadêmico, porém, foi possível observar que com uma base de imagens maior e melhor trabalhada poderíamos obter melhores resultados e assim chegarmos a implementação de um sistema de controle de frequência acadêmica confiável. O levantamento dessas informações contribuiu para o conhecimento da área de reconhecimento facial, assim como, para melhor entendimento de desenvolvimento de trabalhos futuros.

5.1 Trabalhos Futuros

Como proposta de trabalhos e melhorias futuras:

- Visando os resultados obtidos neste projeto de pesquisa, desenvolver uma nova base de dados melhorando as expressões e variações das imagens para que possamos melhorar a taxa de reconhecimento facial deste algoritmo.
- Melhorar a qualidade das imagens capturadas para realização da base de dados e dos testes, utilizando técnicas de redimensionamento mais robustas.
- Melhorar os filtros de detecção facial para que o mesmo possa detectar se é de fato um indivíduo que está sendo identificado e não apenas uma imagem de celular
- Integrar todo o processo em um software servidor para que possa ser consultado como serviço na web

- Conseguir realizar testes com modelos 3D para mapeamento de feições na tentativa de validar o modelo e alcançar melhores resultados.
- Outro ponto de sugestão é o posicionamento das câmeras de segurança existentes nas salas para realizar a melhor detecção das imagens dos indivíduos buscando obter imagens mais adequadas e de forma mais variada para o treinamento do algoritmo.
- Desenvolver o protótipo de um sistema de Controle de Frequência Acadêmica utilizando Reconhecimento Facial, seja por meio da captura de uma imagem (foto) ou pela captura em tempo real por meio de uma câmera interna.

Referências Bibliográficas

AHONEM, T.; HADID, A; PEITKAINEN, M. **Face Recognition with local binary Patterns. ECCV – European Conference on Computer Vision**, Prague / Czech Republic, 2004

AHONEM, T.; HADID, A; PEITKAINEN, M. **Face Recognition with local binary Patterns: Application to face Recognition IEEE Transactions on PAMI**, 2006

ARTERO, ALMIR OLIVETTE. **Inteligência Artificial – Teórica e Prática**. Editora: Livraria da Física, São Paulo, 2009

AMARAL, V. do; GIRALDI, G.A.; THOMAZ, C.E. **Lbp estatísticos aplicado ao reconhecimento de expressões faciais** 2013.

BELHUMEUR, P. N., HESPANHA, J. P., KRIEGMAN, D. J. “**Eigenfaces vs. fisherfaces: recognition using class specific linear projection**,” **IEEE Transactions on Pattern Analysis and Machine Intelligence**, vol. 19, no. 7, pp. 711-720, July 1997.

BRAGA, A.; CARVALHO, A. C.; LUDERMIR, T. B. **Redes Neurais Artificiais: Teoria e aplicações**. LTC editora, 2007. ISBN 9788521615644.

CANALTECH. **Waze ou Google Maps: quais as vantagens e desvantagens de cada um?** Disponível em: < <https://canaltech.com.br/software/Waze-ou-Google-Maps/> > Acessado em: 11 de Maio de 2018.

CHAVES, B. B. **Estudo do algoritmo AdaBoost de aprendizagem de máquina aplicado a sensores e sistemas embarcados**. Tese (Doutorado) — Universidade de São Paulo, 2012.

COPPIN, Bem – **Inteligência Artificial**. – Bem Coppin; Tradução e Revisão Técnica Jorge Duarte Pires Valério. – [Reimpr.] – Rio de Janeiro: LTC, 2013

D’more, Luiz Angelo. **Reconhecimento Facial através de limiares individuais por padrão de textura e sub-região facial** / Luiz Angelo D’more - 2016

FIGUEREDO, M. **Reconhecimento de faces aplicado ao problema de pessoas desaparecidas – Estudo de Caso do Eigenfaces**. Dissertação (Mestrado) – SENAI CIMATEC, Salvador, 2011.

FOLHA DE SÃO PAULO. **Amazon quer liderança em inteligência artificial**. Disponível em: < <http://www1.folha.uol.com.br/mercado/2017/12/1940115-amazon-quer-lideranca-em-inteligencia-artificial.shtml> > Acessado em 11 de Maio de 2018

G1, globo.com – **Japoneses criam método para identificar pessoas pelo jeito de andar**. – Disponível em: <<http://g1.globo.com/jornal-nacional/noticia/2015/10/japoneses-criam-metodo-para-identificar-pessoas-pelo-jeito-de-andar.html>>

HEINEN, M. R. **Autenticação de Assinaturas Online utilizando Redes Neurais Artificiais**. In: Autenticação de Assinaturas Online utilizando Redes Neurais Artificiais. São Leopoldo: Universidade do Vale do Rio dos Sinos, 2002. cap. 3, p. 24–40.

HALL, Ernest L. **Computer image processing and Recognition**. New York: Academic Press, 1979. 584p.

INFORCHANNEL – **Biometria facial garante identificação em cursos à distância** – Disponível em: < <https://inforchannel.com.br/2017/08/18/biometria-facial-garante-identificacao-de-cursos-distancia/> >. Acessado em 12 de janeiro de 2018.

LLI, S.; JAIN, A. **Handbook of face recognition**. Springer, 2005. (Springer eBooks collection: Computer science). ISBN 9780387405957.

LI, S. Z.; JAIN A.K. **Handbook of face Recognition – 2º Edição** [S.l.] Springer, 2011

KOVAC, J. PEER, P., SOLINA, F.; **Human skin colour clustering for face detection**”, EUROCON, 2003 – International Conference on Computer as a Tool, IEEE, 2003.

MENDEL, J. M.; MCLAREN, R. W. **Reinforcement learning control and pattern recognition systems**. In: **Adaptive, Learning and Pattern Recognition Systems: Theory and Applications**. [S.l.]: Academic Press, 1970. p. 287–318.

MITCHELL, Tom. **Machine Learning**. WCB / McGrall-Hill – Computer Science Series. Boston, MA. 1997.

Ming-Hsuan Yang, David J. Kriegman, Narendra Ahuja, **Detecting Faces in Images: A Survey**, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol.24, No.1, Janeiro 2002.

MILANO, Danilo; HONORATO, Luciano B. **Visão Computacional**. Disponível em: <http://www.ft.unicamp.br/liag/wp/monografias/monografias/2010_IA_FT_UNICAMP_visaoComputacional.pdf>. Unicamp, 2010. Acesso em 24 de Outubro de 2018.

NETO. Wander F. S; VALLER, Daniel – **Blog Reconhecimento Facial** – Disponível em: < <http://reconhecimentofacial.com.br/blog/> >. Acessado em 12 de janeiro de 2018.

PRADO, Kelvin Salton do. **Comparação de técnicas de reconhecimento facial para identificação de presença em um ambiente real e semicontrolado**. Kelvin Salto do Prado; Orientador, Norton Trevisan Roman. – 2017.

REZENDE, Solange Oliveira. **Sistemas Inteligentes: Fundamentos e Aplicações**. – Organização Solange Oliveira Rezende. – Barueri, SP: Manole, 2005

RUSSELL, STUART J. (Stuart Jonathan), 1962 – **Inteligência Artificial** – Stuart Russel, Peter Norving; tradução Regina Célia Simille. – Rio de Janeiro Elsevier, 2013

TECHTUDO – **Reconhecimento Facial: Facebook muda e avisa quando você aparece nas fotos** – Disponível em: < <https://www.techtudo.com.br/noticias/2017/12/facebook-muda-reconhecimento-facial-e-avisa-quando-voce-aparece-em-fotos.ghtml> > . Acessado em 11 de maio de 2018

TECMUNDO - **Cortana, Siri, Google Now e Tina: qual a melhor assistente pessoal?** – Disponível em: < <https://www.tecmundo.com.br/siri/59361-cortana-siri-google-now-tina-melhor-assistente-pessoal.htm> >. Acessado em 11 de maio de 2018

TECMUNDO - **Facebook: software de reconhecimento consegue identificar tudo em uma foto** – Disponível em: < <https://www.tecmundo.com.br/facebook/88885-facebook-software-reconhecimento-consegue-identificar-tudo-foto.htm> > Acessado em 11 de Maio de 2018

TURK, M. A; PENTLAND, A. P. **Face recognition using eigenfaces**, In *Proc. of the IEEE Computer Society Conferece*. 1991

TORTORA, G. J.; GRABOWSKI, S. R. *Corpo humano: fundamentos de Anatomia e Fisiologia*. 6. Ed. Porto alegre: Artmed, 2006.

YANG, M. H.; KRIEGMAN, D.J.; AHUJA, N. (2002). "**Detecting Faces in Imgens: A survey**", IEEE Transactions on Pattern Analysis and Machine Inteligence. Vol.,24 n.1

ZHAO, Wenyi, et al. "**Face recognition: A literature survey**." *Acm Computing Surveys (CSUR)* 35.4 (2003): 399-458.