

# Reconhecimento Facial: Uma Breve Introdução

Vinicius Ramos Chaves Neves

Universidade Federal Fluminense - Instituto de Computação  
viniciusrcn@id.uff.br

**Abstract:** *This work has the goal of analyzing the challenge which is Facial Recognition and also how a few techniques approach this problem. More specifically, techniques related to Machine Learning and Deep Learning. Use cases will be approached, different techniques in Machine Learning and Deep learning and some motivations that led this problem to receive the attention it gathers today.*

**Resumo:** *Este trabalho tem como objetivo a análise do desafio que é o Reconhecimento de Faces e a abordagem de algumas técnicas utilizadas para resolver este problema, mais especificamente as técnicas relacionadas aos campos de Machine Learning e Deep Learning. Serão abordados casos de uso, técnicas diferentes dentro de Machine Learning e Deep Learning e algumas motivações que levaram este problema a ganhar a atenção que recebe nos dias atuais.*

## 1 Introdução

Graças ao *boom* de informações ocorrido após a invenção da Internet e principalmente com a popularização do uso de redes sociais, técnicas de Inteligência Artificial envolvendo *Machine Learning* e *Deep Learning* possuem muito mais dados publicamente disponíveis para poderem finalmente serem postas em prática, com uma acurácia razoável [11], [7], [5].

Antes de Warren McCulloch e Walter Pitts apresentarem um artigo científico em 1943 sobre Redes Neurais Artificiais (RNA) em [12], considerado por muitos o marco inicial da Inteligência Artificial, a humanidade já sonhava com máquinas que possuíssem “inteligência” comparável à do ser humano. Apenas alguns anos atrás, essas ideias começaram a receber financiamento e atenção graças ao poder computacional atingido atualmente e às inúmeras formas de que essas técnicas podem ser postas em prática no mundo cada vez mais digital e conectado de hoje em dia.

Como pode ser percebido pela Figura 1, analisando apenas a popularidade da rede social mais utilizada atualmente, a quantidade de dados públicos vem aumentando bastante ao longo do tempo. E isso apenas em uma rede social. Em 2020, o Facebook já possui mais de 2.5 bilhões de usuários.




Figura 1: Popularidade do facebook ao longo dos anos [4]

Considerando esta como uma rede social onde usuários costumam postar fotos próprias e de amigos, a quantidade de imagens que pode ser utilizada em algoritmos de *Machine Learning* (ML) e *Deep Learning* (DL) para reconhecimento facial nunca foi tão grande e ainda tende a aumentar cada vez mais rápido.

Este trabalho tem como objetivo explorar uma das muitas aplicações de ML e DL que é a de Reconhecimento de Faces. São discutidas algumas técnicas utilizadas, desafios, o porquê deste problema receber tanta atenção e como o cenário atual está em relação à pesquisa e quanto à aplicação.

O restante do texto está estruturado da seguinte forma. A Seção 2 apresenta a definição do problema e alguns casos de uso atual mencionando também motivos para ele ter ganho atenção atualmente. A Seção 3 apresenta um breve resumo sobre o que seriam as Redes Neurais Convolucionais, técnica muito utilizada em *Deep Learning*, e também é mostrado um gráfico onde se pode observar a melhora da acurácia das Redes após a introdução desta técnica. Na seção 4 são abordadas algumas técnicas utilizadas divididas em 2 categorias: técnicas baseadas em características na Seção 4.1 e técnicas baseadas em imagens na Seção 4.2. Na Seção 5 são apresentados alguns dos desafios atuais neste problema e possíveis soluções propostas. O papel é concluído com a Seção 6 onde é discutida de forma geral as outras Seções e um dos muitos caminhos que poderão ser seguidos no futuro para melhorar a eficácia das técnicas já existentes e alguns acontecimentos que contribuem para a evolução da computação voltada para o desenvolvimento e investimento cada vez maior nesta área.

## 2 Definição do problema e usos atuais de Reconhecimento Facial

O problema pode ser definido em uma simples frase: detectar rostos em imagens ou vídeos e identificá-los dentro de um banco de dados [11]. Para um ser humano, isto é simples. Desde o nascimento, os humanos possuem contato com pelo menos nossos cuidadores e aprendem a reconhecer que o rosto fica no centro da cabeça. Na maioria dos casos possui dois olhos, um nariz, uma boca e é delimitado por um queixo, testa e bochechas nos lados da face. Aprende-se isso, através de ver o mesmo padrão repetido diversas vezes e com isso aprende-se a diferenciar as pessoas, sub-conscientemente extraindo características diferentes de cada uma e buscando na memória quem aquela pessoa é. E é da mesma forma que cientistas tentam resolver esse problema computacionalmente: fazendo o computador reconhecer o "padrão" de um rosto humano em imagens e vídeos e associá-lo a determinada pessoa.

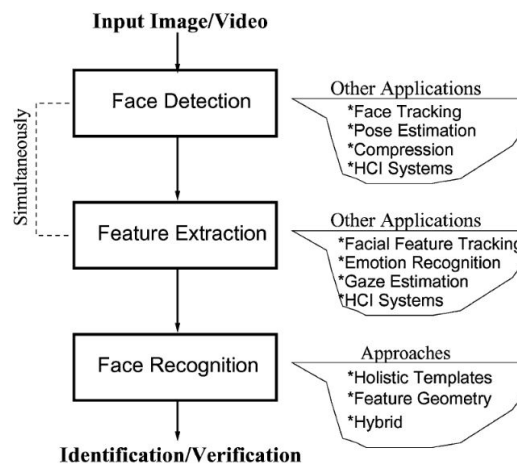


Figura 2: Exemplo de um *pipeline* de um sistema de reconhecimento facial genérico [11]

Um computador trabalha com bits. Então, precisa-se representar as faces usando bits. Este problema já foi resolvido há muito tempo, através do uso de câmeras digitais. Mas o problema de como fazê-lo reconhecer um padrão no meio de milhões de bits continua. É aí que entram as técnicas de *Machine Learning* e *Deep Learning* que utilizam diversas técnicas baseadas em estatística avançada e outras áreas matemáticas.

Este problema começou a receber atenção especial, após perceberem suas aplicações, no mundo militar e comercial. Assim como também, após 30 anos de pesquisa, finalmente, desenvolveu-se a tecnologia necessária, para atingir uma acurácia razoável [11]. Como exemplos mais tangíveis, possuímos a tentativa

de identificar pessoas procuradas, através de câmeras de segurança, em locais públicos. Outros exemplos são desbloqueio de dispositivos eletrônicos, como celular e notebook. Nestes dois últimos exemplos, não é utilizado apenas o reconhecimento de um rosto, mas, além disso, o reconhecimento de quem pertence aquele rosto. Há também câmeras que ajustam seu foco automaticamente em rostos detectados, aplicativos de rede social que aplicam filtros em rostos detectados, etc. As possibilidades são quase infinitas.



Figura 3: Um exemplo de rostos sendo detectados em uma imagem [2]

Usando grandes bases de dados privados no *Labeled faces in the Wild* (LFW), vários grupos conseguiram atingir uma alta performance entre 97% e 99%, chegando assustadoramente próximos da acurácia de um ser humano [5]. Ainda, de acordo com [5], o maior problema não está no algoritmo em si mas sim na quantidade de dados disponível para treinar uma Rede Neural com uma boa eficácia. Com isso, é afirmado mais uma vez a importância do *boom* de dados públicos disponíveis que as redes sociais criaram para o desenvolvimento de projetos envolvendo este tipo de problema.

### 3 Redes Neurais Convolucionais

Esta seção explica brevemente o que é uma Rede Neural Convolutacional e são apresentadas algumas características. A diferença entre uma Rede Neural simples e uma profunda (*deep*) está no fato de que a última possui pelo menos 2 ou mais camadas internas.

O termo "convolutacional" simplesmente indica que, em pelo menos uma das camadas da rede neural, é aplicada uma operação matemática chamada de convolução ao invés da comumente utilizada multiplicação de matrizes.

De acordo com [6], a escolha de design mais importante, no atual estado da arte de classificação de imagens e reconhecimento de objetos, está nas características visuais representadas ou na forma como a imagem em si é representada.




Figura 4: Comparação entre uma Rede Neural Simples e uma Rede Neural Profunda. É no último caso em que são utilizadas as técnicas de convolução [10]

É dito que a melhora quantitativa no problema de reconhecimento de imagens nos últimos 12 anos pode ser dada à introdução de representações melhoradas, utilizando métodos que vão desde o *Bag-of-Visual-Words* (BOVW) até o *(Improved) Fisher Vector* (IFV) [6]. Uma característica comum destes métodos é que eles são, em grande parte, relativamente simples. Atualmente, estas abordagens demonstraram ter uma acurácia menor quando comparadas a métodos que utilizam Redes Neurais Convolucionais atuais.

Como podemos ver na Figura 5, CNN-S com *fine-tuning* (ajustes feitos à mão) possui uma precisão de 82.42%. De acordo com [6], este valor é bem próximo do estado da arte atual. Outra questão interessante das Redes Neurais Convolucionais, que é mencionada em [6], é de que nelas foi observada a possibilidade de reduzir bastante o tamanho da sua camada de *output* sem que isso tenha um efeito adverso na performance.

## 4 Algumas técnicas de reconhecimento facial

Esta Seção descreve dois tipos de técnicas: (*Feature based approaches* e *Image based approaches*). Ambas discutidas em [2].



Figura 5: Comparação de diferentes Redes Neurais. As Redes Neurais Convolucionais foram introduzidas a partir de 2013 [6]

Na Figura 5 é possível ver a comparação entre algumas diferentes técnicas. As Redes Convolucionais mencionadas na Seção 3 foram introduzidas em 2013 na Rede DeCAF. É possível ver uma uma melhora significativa a partir do momento que as Redes Convolucionais foram introduzidas graças a sua acurácia superior e maior facilidade de *tuning* quando comparada à outras técnicas.

#### 4.1 Técnicas baseadas em características

*Active Shape Model* (ASM) é um modelo que foca em detectar características complexas e outros detalhes de mais alto nível. O foco principal é detectar e extrair partes chave do objeto sendo analisado. No caso de um rosto humano, isto seriam os olhos, lábios, nariz, sobrancelhas, etc. O estágio de treino de um ASM consiste na construção de um modelo facial estatístico através de imagens com suas características de interesse previamente marcadas. Este modelo pode ser dividido entre 3 grupos: *Snakes*, *Point Distribution Model* e *deformable templates*.



Figura 6: Um exemplo de duas imagens com iluminação diferente. [11]

[2] ainda cita algumas outras características que podem ser utilizadas para a detecção de um rosto. Elas são descritas a seguir.

**Skin Color Base:** Cor é uma característica importante do rosto humano. Usar a cor da pele para encontrar uma face, seja em um vídeo ou imagem, possui diversas vantagens. Uma delas é que o processamento de cor é muito mais rápido do que o de outras características faciais. Mas isso também possui alguns problemas como por exemplo, a iluminação. A representação da cor de um rosto obtido por uma câmera é influenciada pela luz ambiente, movimentação do rosto, etc. Alguns algoritmos utilizados nesta característica demonstram problemas quando outras partes do corpo estão expostas.

**Motion Base:** Em um vídeo, também é possível localizar rostos mesmo que eles estejam em movimento. Rostos e partes corporais em movimento podem ser detectados através da diferença de *pixels* entre quadros (*frames*) consecutivos. Além de faces, é possível detectar expressões faciais também utilizando essa técnica de diferença entre *frames*.

**Gray Scale Base:** As informações dos tons de cinza em um rosto podem ajudar a detectar partes importantes do rosto como sobrancelhas e lábios, que normalmente possuem um tom mais escuro que a área em volta. Vários algoritmos atuais procuram por diferenças locais deste tipo dentro de uma região facial

segmentada. Primeiro, as imagens de *input* são alteradas usando-se *contrast-stretching* e rotinas morfológicas de escalas de cinza, para melhorar a qualidade de locais escuros e assim, facilitar a detecção.

## 4.2 Técnicas baseadas em imagens

**Redes Neurais:** Redes neurais avaliam pequenas partes de uma imagem e decidem se existem rostos nela ou não. O sistema é distribuído através de diversas redes para melhorar o desempenho quando comparado com apenas uma rede. Elas são constituídas de camadas onde cada camada  $N$  desenvolve um *output* para a camada  $N+1$ . O que cada nó pertencente às camadas faz depende de muitas variáveis. Algumas seriam o tipo de rede neural, métodos, características a serem levadas em conta, profundidade da rede (quantidade de camadas), etc. Um exemplo de uma Rede Neural simples e uma profunda pode ser visto na Figura 4.

**Eigen Faces Method:** *Eigenvectors* já foram usados em reconhecimento facial com Redes Neurais simples que trabalhavam com imagens alinhadas e normalizadas. As imagens podem ser codificadas linearmente usando uma pequena amostra. *Eigen pictures* é o nome dado ao conjunto de vetores-base ótimos pois eles são apenas *Eigenvectors* de matrizes de covariância calculadas a partir das imagens no conjunto de treino.



Figura 7: Exemplo de *Eigen faces* [2]

O artigo [9] ainda cita mais uma técnica interessante utilizando **Local Binary Patterns**, onde experimentos demonstraram uma clara superioridade desta técnica quando comparada com outras como *PCA*, *Bayesian Intra/extra personal Classifier* e *Elastic Bunch Graph Matching* de acordo com a sua pesquisa. Ela considera tanto as informações de textura e forma nas informações contidas nas imagens para representar as faces.

A área da face é dividida em regiões menores onde histogramas de *Local Binary Pattern* (LBP) são concatenados entre si para formar um novo histograma espacialmente aprimorado. Este novo histograma representa eficientemente as

imagens faciais. A Figura 8 mostra uma comparação entre o LBP e outras técnicas. Nesse exemplo foi utilizado o conjunto de imagens de teste de FERET dup1. FERET é uma base de imagens utilizada para medir a performance de diferentes algoritmos de reconhecimento facial.

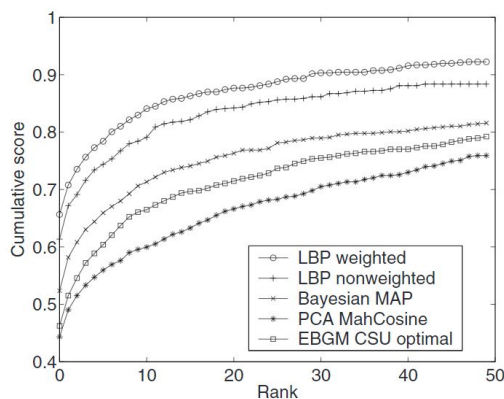


Figura 8: Gráfico comparando as diferentes técnicas mencionadas. Nele pode-se ver que o *LBP weighted* possui maior acurácia que o resto. O *LBP non-weighted* perde para o *Bayesian MAP* [1]

No eixo X do gráfico, apresenta-se o *Rank*. Este gráfico mede a frequência na qual uma pessoa em uma imagem possui sua identidade reconhecida quando buscada ao longo de uma galeria de imagens. O Rank 1 significa que o top1 (escolha mais provável) dita pelo algoritmo, é uma imagem da mesma pessoa buscada. O Rank 2 diz que pelo menos uma imagem no top2 foi escolhida corretamente. Essa lógica continua até o Rank 50 (top50 de imagens mais prováveis onde pelo menos uma é da pessoa buscada).

## 5 Desafios

Esta seção discute alguns desafios e algumas soluções propostas para facilitar o reconhecimento de faces em diversas situações difíceis. Algumas dessas situações seriam o efeito de *blur*, iluminação inadequada, faces em diferentes poses, etc. Serão abordados os problema de *blur*, poses diferentes e variação de idade.

**Blur:** O efeito de *Blur* se caracteriza como um borrão que talvez impeça ou pelo menos dificulte a visualização da imagem. De acordo com [9], este problema foi pouco pesquisado quando comparado com outros como iluminação, poses, etc. Diferentes descritores robustos foram propostos e implementados para outras soluções, mas *Blur* continua sendo algo que recebe pouca atenção.

Este problema é extremamente comum pois pode ser causado por inúmeros fatores como a câmera não estar em foco, a pessoa estar em movimento, baixa qualidade da imagem como no exemplo de uso de uma *webcam* comum, etc.



[9] ainda afirma que algumas poucas publicações dedicadas à diminuição deste efeito, chamada de *Deblurring*, foram feitas. Porém, descritores construtivos voltados para a invariância do *Blur* não foram propostos ainda, mas [9] faz um estudo do uso de *Local Phase Quantization* (LPQ).



Figura 9: Efeito de Blur [9]

Um exemplo de *Blur* pode ser visto na Figura 9. O operador de *Local Phase Quantization* (LPQ) é usado para o reconhecimento em imagens com este problema. LPQ é baseado na quantização da fase de Transformada de Fourier em locais vizinhos.

Na análise de faces, histogramas dos rótulos LPQ computados em regiões locais são usados como descritores faciais, similares aos do *Local Binary Pattern* (LBP), mencionado na Seção 4 em *Eigen Face Method*. Experimentos realizados nos *datasets* CME PIE e FRGC 1.0.4 mostraram que o LPQ possui uma eficácia melhor que o LBP em imagens borradas e imagens nítidas.

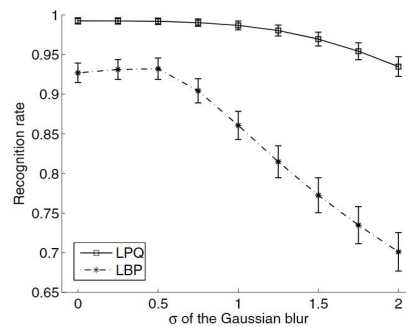


Figura 10: Gráfico comparando os resultados de LPQ e LBP onde o eixo X representa a variação do *Blur Gaussiano* [9]

**Diferentes posicionamentos do rosto:** Reconhecer um rosto que não esteja voltado de frente para a câmera é desafiador pois não é possível retirar identificadores faciais completos, como por exemplo no caso de uma pessoa estar de lado ou com o rosto levemente virado. O artigo [3] discute este problema e propõe um sistema em tempo real para detecção, reconhecimento e rastreamento da face ao longo de um vídeo, estejam os rostos de frente, perfil ou inclinados.

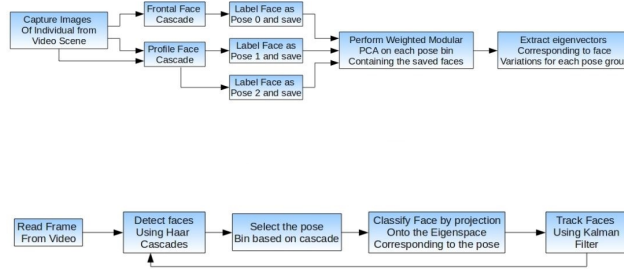


Figura 11: Esquema de treino na parte superior e teste na parte inferior na classificação de rostos do sistema proposto por [3]

O algoritmo consegue fazer isso extraíndo as características "Haar" e as usa num esquema de classificadores em cascata. A pose é determinada pelo algoritmo de detecção facial que utiliza uma combinação das imagens em cascata e, dependendo da pose, a face é comparada com um conjunto de imagens com uma pose aproximadamente semelhante para classificá-la.

Por fim, as faces detectadas são reconhecidas ao serem projetadas em um *Eigenspace*, semelhante à *Eigen Faces Method*, mencionada na Seção 4, obtido na fase de treino usando a *Modular Weighted PCA*. Em seguida, rastreados utilizando o filtro rastreador de múltiplas faces, *Kalman*. A *Modular Weighted PCA* é uma técnica estatística derivada da *Principal Component Analysis* (PCA) que tem como objetivo a redução de variáveis no reconhecimento de uma face.

O sistema proposto obteve como resultado cerca de 220 detecções em 500 quadros da sequência de vídeo. 22 foram detectadas como "desconhecidas" e o resto foi detectado corretamente, com apenas 4 ou 5 identidades incorretas. Isso constitui uma acurácia de aproximadamente 88%.

**Variação de idade:** Um dos problemas mais interessantes e um dos mais difíceis de ser resolvido é o de reconhecer um rosto quando há uma significativa variação de idade no *dataset* de treino e na imagem sendo testada. Este problema possui tamanha complexidade dado o fato de que o processo de envelhecimento afeta tanto a forma quanto a textura da face.

De acordo com [8], uma possível solução para isso seria a aplicação de um modelo probabilístico que representaria tanto a face quanto a sua variável de identidade, que se mantém estável ao longo do tempo, junto com a variável de envelhecimento, que muda ao longo do tempo.



Figura 12: Um conjunto de imagens da mesma pessoa, em épocas diferentes. Este tipo de conjunto junto com outros que seguem a mesma lógica foi usado para treinar o sistema em [8]

A solução proposta em [8] envolve *Deep Learning* e uma abordagem baseada em conjuntos para auxiliar no reconhecimento facial de alguém submetido ao processo de envelhecimento. As fotos de treino de cada face, tendo sido tiradas em épocas diferentes, são tratadas como um conjunto só. Depois, este conjunto é comparado com o conjunto de outras faces, construído da mesma forma.

Características faciais são extraídas usando uma Rede Neural Convolutiva, brevemente explicada na Seção 3. Os resultados no experimento realizado em [8] mostram que tanto a detecção quanto o reconhecimento de faces possui uma performance melhor ao se usar abordagens baseadas em conjuntos. Também foi observado que ao utilizar este tipo de técnica, é mais fácil reconhecer pessoas mais idosas a partir de imagens mais jovens (da mesma pessoa) do que reconhecer uma pessoa mais jovem a partir de imagens desta pessoa envelhecida.

Infelizmente o estudo não cita em números a eficácia do sistema proposto. Ele mais ensina a construir um sistema deste tipo do que discute seus próprios resultados, porém, ele cita importantes casos cotidianos no qual algo assim pode ser aplicado: no caso de crianças desaparecidas ainda sendo procuradas anos depois, no caso de alguma pessoa ter falsificado diferentes documentos ao longo de vários anos, etc. Esta categoria de problema ainda abrange um grande espaço inexplorado que pode vir a ter inúmeras aplicações no futuro.

## 6 Conclusão

Como pode-se perceber neste trabalho, o desafio do Reconhecimento Facial ainda possui um amplo espaço não estudado e inúmeras aplicações, muitas ainda provavelmente nem pensadas. Foram comentadas algumas técnicas e aplicações mas há muitas outras técnicas diferentes, experimentos realizados ou imaginados e as inúmeras aplicações em que o reconhecimento de rostos pode ser aplicada.

Com o resultado de algum dos experimentos, é possível perceber que o atual estado da arte chega próximo ao de um cérebro humano, mas ainda não é confiável o suficiente dependendo da aplicação em que seja utilizado. Por isso os estudos constantes e experimentos são necessários. Com o auxílio de computadores cada vez mais potentes, sistemas distribuídos mais eficientes e o rápido avanço no desenvolvimento de GPUs (fundamentais para técnicas de *Deep Learning*), chega-se cada vez mais próximo de uma acurácia que possa competir com a humana. Por exemplo, ainda é um desafio reconhecer pessoas usando fotos tiradas em épocas diferentes. Seres humanos possuem um pouco de dificuldade com isso, mas computadores podem vir a aprender padrões que nem o cérebro humano enxerga.

## Referências

- [1] Hadid A. Ahonen T. «Face Recognition with Local Binary Patterns». Em: *Computer Vision - ECCV 2004. ECCV 2004. Lecture Notes in Computer Science* (2004). URL: [https://link.springer.com/content/pdf/10.1007/5C%2F978-3-540-24670-1\\_36.pdf](https://link.springer.com/content/pdf/10.1007/5C%2F978-3-540-24670-1_36.pdf).
- [2] Amandeep Kaur Ashu Kumar. «Face detection techniques: a review». Em: *Springer* (2018). URL: [https://www.researchgate.net/profile/Munish\\_Kumar16/publication/326667118\\_Face\\_Detection\\_Techniques\\_A\\_Review/links/5db59d0a92851c577eca8abb/Face-Detection-Techniques-A-Review.pdf?origin=publication\\_detail](https://www.researchgate.net/profile/Munish_Kumar16/publication/326667118_Face_Detection_Techniques_A_Review/links/5db59d0a92851c577eca8abb/Face-Detection-Techniques-A-Review.pdf?origin=publication_detail).
- [3] Jacob Foytika Binu Muraleedharan Naira. «Multi-Pose Face Recognition And Tracking System». Em: *Procedia Computer Science* (2011). URL: [https://www.researchgate.net/profile/Binu\\_Nair/publication/220308049\\_Multi-Pose\\_Face\\_Recognition\\_And\\_Tracking\\_System/links/09e4150251b2bc5e09000000/Multi-Pose-Face-Recognition-And-Tracking-System.pdf?origin=publication\\_detail](https://www.researchgate.net/profile/Binu_Nair/publication/220308049_Multi-Pose_Face_Recognition_And_Tracking_System/links/09e4150251b2bc5e09000000/Multi-Pose-Face-Recognition-And-Tracking-System.pdf?origin=publication_detail).
- [4] J. Clement. «Number of monthly active Facebook users worldwide as of 1st quarter 2020». Em: *Statista* (2020). URL: <https://www.statista.com/statistics/264810/number-of-monthly-active-facebook-users-worldwide/>.
- [5] Zhen Lei Dong Yi. «Learning Face Representation from Scratch». Em: *Center for Biometrics and Security Research and National Laboratory of Pattern Recognition Institute of Automation, Chinese Academy of Sciences (CASIA)* (2014). URL: <https://arxiv.org/pdf/1411.7923.pdf>.
- [6] Karen Simonyan Ken Chatfield. «Return of the Devil in the Details: Delving Deep into Convolutional Nets». Em: *British Machine Vision Conference* (2014). URL: <https://arxiv.org/pdf/1405.3531.pdf>.

- [7] Zisserman A Parkhi OM Vedaldi A. «Deep Face Recognition». Em: *British Machine Vision Conference* (2015). URL: [https://ora.ox.ac.uk/objects/uuid:a5f2e93f-2768-45bb-8508-74747f85cad1/download\\_file?file\\_format=pdf&safe\\_filename=parkhi15.pdf&type\\_of\\_work=Conference+item](https://ora.ox.ac.uk/objects/uuid:a5f2e93f-2768-45bb-8508-74747f85cad1/download_file?file_format=pdf&safe_filename=parkhi15.pdf&type_of_work=Conference+item).
- [8] Thippeswamy G Prathama V. «Age Invariant Face Recognition». Em: *International Journal of Trend in Scientific Research and Development (ijtsrd)* (2019). URL: [https://www.researchgate.net/publication/334124014\\_Age\\_Invariant\\_Face\\_Recognition/fulltext/5d18f2d7458515c11c0642ee/334124014\\_Age\\_Invariant\\_Face\\_Recognition.pdf?origin=publication\\_detail](https://www.researchgate.net/publication/334124014_Age_Invariant_Face_Recognition/fulltext/5d18f2d7458515c11c0642ee/334124014_Age_Invariant_Face_Recognition.pdf?origin=publication_detail).
- [9] Esa Rahtu Timo Ahonen. «Recognition of Blurred Faces Using Local Phase Quantization». Em: *Recognition of Blurred Faces Using Local Phase Quantization* (2008). URL: [International%20Conference%20on%20Pattern%20Recognition](https://www.researchgate.net/publication/220611647_International_Conference_on_Pattern_Recognition).
- [10] Favio Vásquez. «Deep Learning made easy with Deep Cognition». Em: *Medium* (2017). URL: <https://becominghuman.ai/deep-learning-made-easy-with-deep-cognition-403fbe445351>.
- [11] R. CHELLAPPA W. ZHAO. «Face Recognition: A Literature Survey». Em: *ACM Computing Surveys* (2003). URL: <https://dl.acm.org/doi/pdf/10.1145/954339.954342>.
- [12] WALTER PITTS WARREN S. MCCULLOCH. «A LOGICAL CALCULUS OF THE IDEAS IMMANENT IN NERVOUS ACTIVITY». Em: *Bulletin of Mathematical Biophysics* (1943). URL: <https://www.cs.cmu.edu/~./epxing/Class/10715/reading/McCulloch.and.Pitts.pdf>.