UNIVERSIDADE ESTADUAL PAULISTA "JÚLIO DE MESQUITA FILHO"
FACULDADE DE CIÊNCIAS - CAMPUS BAURU
DEPARTAMENTO DE COMPUTAÇÃO
BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO

RAFAEL TATSUKI TAKAGI

UTILIZAÇÃO DE REDES NEURAIS PARA A CRIAÇÃO DE UM GERADOR E EDITOR DE FACES

BAURU
Novembro/2019

RAFAEL TATSUKI TAKAGI

UTILIZAÇÃO DE REDES NEURAIS PARA A CRIAÇÃO DE UM GERADOR E EDITOR DE FACES

Trabalho de Conclusão do Curso de Bacharelado em Ciência da Computação da Universidade Estadual Paulista "Júlio de Mesquita Filho", Faculdade de Ciências, Campus Bauru.
Orientador: Prof. Associado Aparecido Nilceu Marana

BAURU
Novembro/2019

Rafael Tatsuki Takagi Utilização de Redes Neurais para a criação de um gerador e editor de faces/ Rafael Tatsuki Takagi. – Bauru, Novembro/2019-
42 p. : il. (algumas color.) ; 30 cm.
Orientador: Prof. Associado Aparecido Nilceu Marana
Trabalho de Conclusão de Curso – Universidade Estadual Paulista "Júlio de Mesquita Filho"
Faculdade de Ciências
Bacharelado em Ciência da Computação, Novembro/2019.
1. Ciência da Computação 2. Redes Neurais 3. Encoder 4. Decoder 5. Python

Rafael Tatsuki Takagi

Utilização de Redes Neurais para a criação de um gerador e editor de faces

Trabalho de Conclusão do Curso de Bacharelado em Ciência da Computação da Universidade Estadual Paulista "Júlio de Mesquita Filho", Faculdade de Ciências, Campus Bauru.

Banca Examinadora

Prof. Associado Aparecido Nilceu Marana
Orientador
Universidade Estadual Paulista "Júlio de Mesquita Filho"
Faculdade de Ciências
Departamento de Ciência da Computação

Profa. Dra. Simone das Graças Domingues Prado
Universidade Estadual Paulista "Júlio de Mesquita Filho"
Faculdade de Ciências
Departamento de Computação

Prof. Dr. Clayton Reginaldo Pereira
Universidade Estadual Paulista "Júlio de Mesquita Filho"
Faculdade de Ciências
Departamento de Computação

Bauru, _____ de _____ de _____.

Dedico este trabalho à minha família, ao Circo e à todos que me apoiaram nesta jornada.

Agradecimentos

Agradeço à minha família por todo o apoio dado, físico e mental, ao longo desses quatro anos.

Aos amigos que fiz durante a graduação, especialmente ao pessoal do Circo, sem eles eu não chegaria até aqui com tantas memórias.

Ao meu orientador Prof. Associado Aparecido Nilceu Marana por aceitar ser meu orientador mesmo estando carregado de tarefas e outros orientandos.

Ao pessoal do Carrossel Caipira por me darem a oportunidade de fazer parte do time e participar do projeto.

Ao ex-aluno Gustavo Rosa pela construção do modelo de TCC em Latex.

À UNESP por proporcionar esta oportunidade de cursar um curso superior não tão distante de minha terra natal.

À todos que de alguma forma me ajudaram nessa experiência universitária.

É meio que uma lei da natureza. O objetivo que alguém almeja raramente pode ser alcançado por um caminho simples.

Konosuke Matsushita

Existe um provérbio japonês que literalmente diz 'ice as velas com sua mão dominante', significa que você deve ir atrás das oportunidades que aparecem na sua vida com o que você tiver de melhor para realizá-las.

Soichiro Honda

Resumo

A ideia de poder gerar e editar faces humanas é algo interessante pois estas podem ter várias aplicações como o uso em personagens de jogos ou de animações. Dependendo de quantas faces são desejadas, é extenuante para uma pessoa criar faces manualmente. Para facilitar este trabalho, uma aplicação que possa automatizar a geração e edição de faces pode ser muito interessante e útil. A aplicação desenvolvida neste projeto busca ser um gerador e editor de faces de baixo custo computacional, visto que algumas aplicações existentes similares exigem muito poder computacional. Para isso os conceitos de *auto-encoder* e o de PCA foram utilizados para extrair as características importantes de uma face humana que podem ser alteradas para gerar de uma face diferente.

Palavras-chave: *Auto-encoder*. PCA. Redes Neurais Convolucionais. Aprendizado de Máquina. Geração e Edição de Faces.

Abstract

The idea of generating and editing human faces is interesting as they can be used in a plethora of applications such as video game or animation characters. Depending on how many faces are desirable, it is tiresome for someone to create faces manually. Therefore, it is very interesting and useful the existence of an application that automatise such task. The application developed in this work longs to be an face generator and editor that does not require high amounts of computational power, since some similar existing applications require high amounts of computational power. To reach this objective the concept of auto-encoder and the concept of PCA were applied to extract prominent features of a human face that can be altered to generate a different face.

Keywords: Auto-encoder. PCA. Convolutional Neural Networks. Machine Learning. Face Generator and Editor.

Lista de figuras

Lista de códigos

Lista de abreviaturas e siglas

CNN	*Convolutional Neural Network*
GAN	*Generative Adversarial Network*
IA	Inteligência Artificial
ML	*Machine Learning*
MTCNN	*Multi-task Cascaded Convolutional Networks*
PCA	*Principal Component Analysis*
RAM	*Random-access memory*
RNA	Redes Neurais Artificiais
ReLU	*Rectified Linear Unit*

Sumário

1 Introdução

Atualmente, a ideia de poder criar e editar faces humanas é algo que prende a atenção das pessoas, muitas já tentaram imaginar como elas seriam se certa parte do rosto delas fosse um pouco diferente, tanto que o site *This Person Does Not Exist* (KARRAS; LAINE; AILA, 2018) causou certa movimentação em sites de notícias sobre tecnologia no Brasil e no mundo. Como é inviável que uma pessoa possa criar uma quantidade enorme de faces humanas realistas, como por exemplo para uma personagem de um jogo ou para a criação de uma base de dados de faces humanas artificiais para uso em outros projetos, uma aplicação utilizando Inteligência Artificial (IA) foi desenvolvida por Karras, Laine e Aila (2018).

Uma outra maneira possível de desenvolver uma aplicação utilizando IA que realize feitos similares é com a utilização de *encoders* e *decoders*, mais precisamente no conceito dos *Auto-Encoders* (DOERSCH, 2016).

Um *Encoder* tem a função de traduzir algum arquivo em código, seja imagem, áudio, vídeo ou até mesmo outro código. Seu principal uso é o de padronização e compressão. Um *Decoder* tem a função oposta, reconstruindo o arquivo original a partir do código gerado por um *encoder*.

Russell e Norvig (2009) definem Inteligência Artificial como o campo que estuda "agentes inteligentes": qualquer dispositivo que observa seu ambiente e realiza ações que maximizam suas chances de sucesso em alcançar determinado objetivo. Russell e Norvig (2009) também definem que coloquialmente IA é utilizado para descrever máquinas ou computadores que imitam funções cognitivas características de humanos, como aprendizado e a capacidade de solucionar problemas.

1.1 Problema

A tarefa de mentalmente criar e modificar faces a partir de informações dadas sobre a composição delas é simples para um ser humano, mas para uma máquina é um desafio considerável pois, diferentemente de um ser humano que utiliza vários outros recursos para identificar objetos em uma imagem, a máquina utiliza um conjunto de números como ilustra a Figura 1.

Uma maneira possível de obter os resultados desejados é utilizar *auto-encoders*. Neste caso deve-se obter um conjunto de faces para treinar o *auto-encoder* e utilizar o modelo criado para a geração das faces.

Figura 1 – O que o ser humano vê e o que a máquina vê.

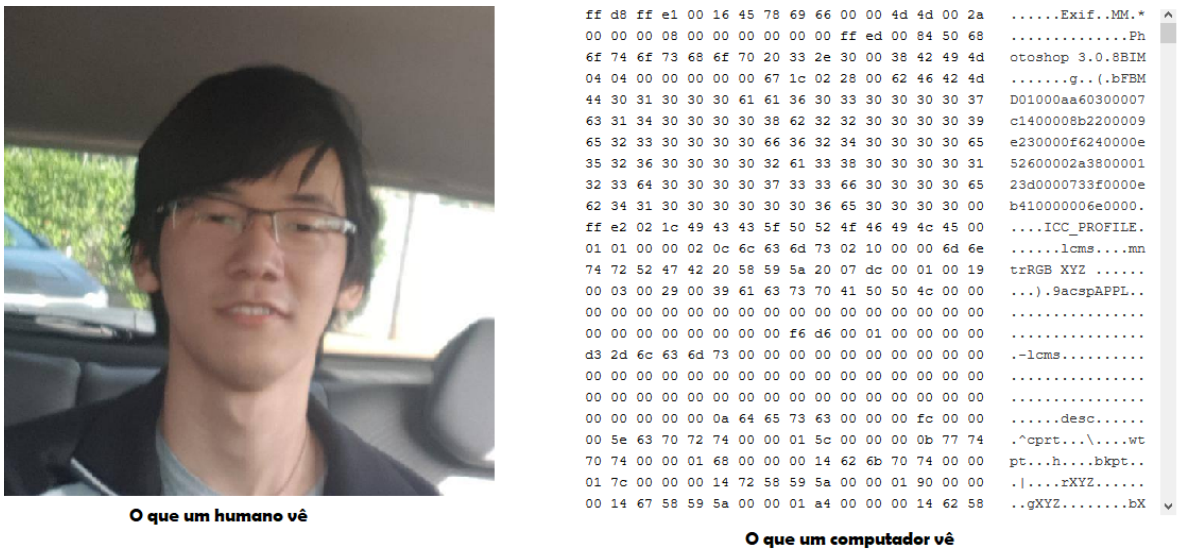

Fonte: Elaborada pelo autor.

1.2 Objetivos

O objetivo deste trabalho foi desenvolver uma ferramenta para possibilitar a criação e edição de faces a partir de parâmetros dados pelo usuário, como largura da face, posição dos olhos e sobrancelhas e expressões faciais.

Tal ferramenta não deverá exigir um alto poder computacional, devendo rodar sem travamentos em um computador pessoal com componentes razoáveis e sem placa de vídeo dedicada.

1.3 Desafios

Um dos desafios é a obtenção de um banco de imagens onde as pessoas estejam em posições similares para não haver muita discrepância em dados como a posição do nariz em relação ao queixo como ilustra a Figura 2, pois o fato do conjunto de treinamento não ser uniforme irá impactar na qualidade do modelo criado.

Uma maneira de diminuir as discrepâncias entre as posições dos rostos nas imagens é utilizar uma ferramenta de detecção e reconhecimento de faces humanas, como redes neurais convolucionais multitarefas em cascata (*Multi-task Cascaded Convolutional Neural Networks*, MTCNN)[1] e o *Face Recognition*[2].

[1] Disponível em <https://github.com/ipazc/mtcnn>.
[2] Disponível em <https://github.com/ageitgey/face_recognition>.

Figura 2 – Diferença entre a posição de detalhes entre duas faces.

Fonte: Elaborada pelo autor.

Outro desafio é a definição dos parâmetros: o que deve ser alterado nos parâmetros para a geração de uma face nova ou para alterar uma face já gerada.

Para isso a utilização da técnica de Análise de Componente Principal (*Principal Component Analysis*, PCA) é utilizada. Esta técnica determina quais características das imagens de treinamento são as mais importantes e que, portanto, devem ser utilizadas como os parâmetros de geração e edição das faces.

1.4 Organização da monografia

Além deste capítulo introdutório, que apresenta a motivação, os objetivos e os desafios do projeto, esta monografia possui outros seis capítulos, apresentados a seguir.

O Capítulo 2 apresenta a fundamentação teórica necessária para o entendimento e organização do trabalho, incluindo os conceitos sobre Aprendizado de Máquina e Redes Neurais Artificiais que foram utilizados.

O Capítulo 3 exibe aplicações similares ao desenvolvido neste trabalho.

O Capítulo 4 descreve os materiais, as ferramentas e os métodos utilizados no desenvolvimento deste trabalho.

O Capítulo 5 relata o processo de desenvolvimento e uso, desde a obtenção e tratamento do conjunto de dados até o desenvolvimento do programa. Ao final do capítulo, breves instruções de como utilizar um conjunto diferente para o treinamento são disponibilizadas.

O Capítulo 6 relata os testes realizados durante o desenvolvimento e as validações finais do trabalho.

Por fim o Capítulo 7 apresenta a conclusão da monografia, sugerindo possíveis trabalhos futuros.

2 Fundamentação Teórica

2.1 Processamento de Imagens

Uma imagem pode ser definida como uma função bidimensional $f(x, y)$ onde x e y são coordenadas espaciais e a amplitude de f em qualquer par de coordenadas (x, y) é chamada de intensidade da imagem naquele ponto. Quando os valores das coordenadas e das amplitudes são todas finitas e discretas, tem-se uma imagem digital. O campo de processamento de imagens digitais se refere ao processamento de imagens digitais por meio de um computador (GONZALEZ; WOODS, 2008).

2.2 Aprendizado de Máquina

No início da IA os problemas aplicados eram intelectualmente complicados para humanos mas simples para máquinas pois eram problemas descritos com uma série de regras formais matemáticas. Começou-se a ter um grande desafio quando os problemas nos quais desejava-se aplicar a IA eram simples para humanos porém difíceis para serem descritos por formalidades matemáticas, como, por exemplo, o reconhecimento de faces ou de letras e símbolos.

A dificuldade dos computadores resolverem tais problemas utilizando códigos puros levou à concepção da ideia de que um sistema de IA deve adquirir seu próprio conhecimento, a partir de padrões nos dados apresentados. A esta capacidade dá-se o nome de Aprendizado de Máquina (*Machine Learning*, ML).

ML é um ramo de pesquisa da IA que aborda problemas de maneira diferente, treinando um modelo com base em uma série de exemplos, com um algoritmo sendo usado para modificá-lo e otimizá-lo quando preciso (ALPAYDIN, 2009).

2.2.1 Aprendizado de Máquina Profundo

A hierarquia de conceitos possibilita ao computador aprender conceitos complexos a partir de outros mais simples. Se desenhar um grafo ilustrando como esses conceitos são construídos a partir de outros ele será profundo, com várias camadas. Por este motivo chama-se essa aproximação de Aprendizado Profundo (GOODFELLOW; BENGIO; COURVILLE, 2016).

2.3 Análise de Componente Principal

O PCA é uma técnica estatística que consiste na utilização de transformações ortogonais para converter um dado conjunto de observações de variáveis possivelmente correlacionados para um conjunto de variáveis não correlacionados chamados de Componentes Principais. O PCA é definido de forma que o primeiro componente principal possui a maior variância possível no conjunto inicial, e cada componente seguinte possui a maior variância sob a restrição de ser ortogonal a todos os componentes anteriores.

As principais funções do PCA incluem (WOLD; ESBENSEN; GELADI, 1987): simplificação, redução de dados, modelagem, detecção de ponto fora da curva, seleção de variáveis, classificação, predição, ordenação.

2.4 Redes Neurais Artificiais

Uma Rede Neural Artificial (RNA) é um modelo computacional que é baseado em como o cérebro humano processa informações (KARN, 2016), não sendo um algoritmo em si mas sendo um *framework* onde diversos tipos de algoritmos relacionados ao ML trabalham em conjunto. Em vez de dar um conjunto específico de regras para resolver um problema, é dado um modelo onde se avalia exemplos e uma lista de instruções para modificar o modelo caso hajam falhas. É esperado que após certo tempo um bom modelo deva ser capaz de resolver o problema de forma bem precisa (BUDUMA, 2017).

A arquitetura de uma RNA é baseada no funcionamento de neurônios artificiais que, assim como neurônios biológicos, recebem estímulos de entrada e são ativados caso estes estímulos forem significantes o suficiente, repassando o estímulo processado para outros neurônios conectados.

Um neurônio recebe os estímulos como números e retorna como saída o resultado da aplicação de uma função não linear (geralmente a função sigmoide) na soma dos estímulos. Esta saída ainda é submetida a um ajuste causado por pesos existentes nas conexões entre neurônios. Estes pesos variam de acordo com o aprendizado da rede.

Geralmente os neurônios artificiais estão organizados em camadas dentro de uma RNA e cada camada pode realizar uma operação específica em sua entrada. Os estímulos viajam da primeira camada (a camada de entrada) até a última (a camada de saída) após atravessar múltiplas camadas. A Figura 3 ilustra uma RNA com seis neurônios artificiais de entrada, duas camadas ocultas com 10 neurônios cada e um neurônio de saída.

A arquitetura popular de RNAs em geral indica que antes da utilização de uma RNA para uma tarefa, características da entrada sejam extraídas por meio de camadas da rede. O

Figura 3 – Exemplo de uma RNA.

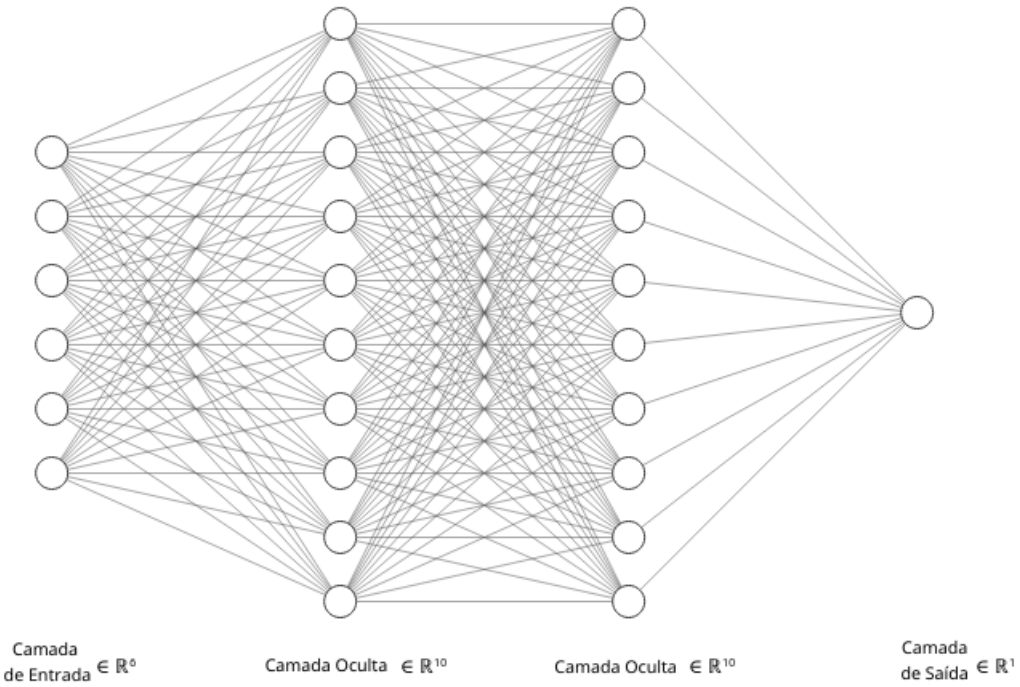

Fonte: Elaborada pelo autor.

espaço latente nada mais é do que a camada onde estão as características da entrada após estas serem extraídas.

2.4.1 Redes Neurais Convolucionais

Redes Neurais Convolucionais (*Convolutional Neural Networks*, CNN) são um tipo especializado de RNA para processar dados organizados em topologias de grade, por exemplo imagens representadas por uma grade bidimensional de pixels. Como seu nome implica, as CNNs aplicam uma operação matemática linear chamada convolução. CNNs são simplesmente RNAs que se utilizam de convolução em vez de uma multiplicação geral matricial em ao menos uma de suas camadas (GOODFELLOW; BENGIO; COURVILLE, 2016).

Convolução é um operador linear que a partir de duas funções gera uma terceira função que expressa como uma função é modificada pela outra. A operação é representada por um asterisco e é definida pela integral do produto de duas funções após uma delas ter sido invertida e transladada como descrita pela Equação 2.1.

$$(f * g)(t) = \int f(a)g(t-a)da \tag{2.1}$$

Pela terminologia utilizada por CNNs, o primeiro argumento (a função f) é denominado entrada e o segundo argumento (a função g) é denominado Kernel.

Para intervalos discretos a Equação 2.2 pode ser utilizada.

$$(f * g)[n] = \sum_{m=-\infty}^{\infty} f[m]g[n-m] \tag{2.2}$$

Em aplicações de CNNs a entrada geralmente é um vetor multidimensional de dados e o kernel um vetor multidimensional de parâmetros adotado pelo algoritmo. Estes vetores multidimensionais podem ser chamados de tensores. Para uma aplicação com entrada bidimensional I e kernel K também bidimensional é utilizada a Equação 2.3.

$$(I * K)(i,j) = \sum_m \sum_n I(m,n)K(i-m, j-n) \tag{2.3}$$

A Equação 2.3 pode ser escrita como segue na Equação 2.4 pois a operação de convolução é comutativa.

$$(K * I)(i,j) = \sum_m \sum_n I(i-m, j-n)K(m,n) \tag{2.4}$$

A utilização da Equação 2.4 é mais simples no campo do ML pois há menos variação no intervalo de valores válidos de m e n.

A Figura 4 ilustra a operação de convolução em uma entrada de duas dimensões e um kernel 2×2, onde cada casa da matriz de saída é resultante do produto escalar entre uma submatriz da entrada com as mesmas dimensões do kernel e o kernel.

Figura 4 – Exemplo de convolução bidimensional.

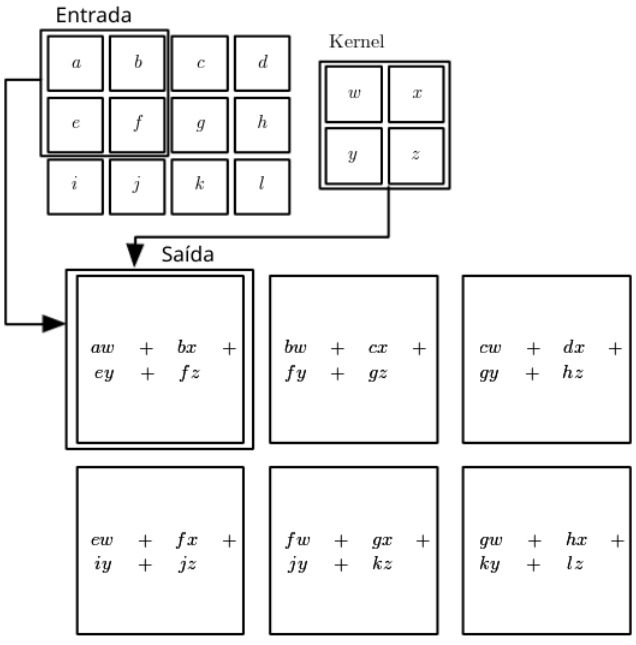

Fonte: Goodfellow, Bengio e Courville (2016).

2.4.1.1 Camada de Convolução

Nesta camada cada neurônio está associado a uma janela de kernel que será aplicada na entrada. Esse kernel é composto pelos valores de pesos das ligações do neurônio. A partir do tensor de entrada original são gerados n tensores resultantes das operações em cada neurônio.

Caso a entrada seja uma imagem, após realizada a convolução é aplicada uma função de ativação de Unidade Linear Retificada (*Rectified Linear Unit*, ReLU) nos tensores. A função é dada por $max(0, x)$ e serve para retirar quaisquer valores negativos que possam existir nos tensores, substituindo-os por zero. Isso pois uma imagem não pode ter valores negativos em seus pixels.

2.4.1.2 Camada de *Pooling*

Esta camada é responsável for diminuir as dimensões dos tensores para diminuir o poder computacional necessário para processar os dados. Para o processo de *pooling* são definidas dimensões nas quais a entrada será dividida em várias submatrizes e a partir dos valores destas submatrizes que é definida a saída.

Existem dois tipos de *pooling*: *Max Pooling* e *Average Pooling*. O *Max Pooling* retorna o valor máximo da submatriz. O *Average Pooling* retorna a média dos valores da submatriz. A Figura 5 ilustra ambos tipos de *pooling* com uma entrada 4×4 e dimensões 2×2 para as submatrizes.

Figura 5 – Exemplos de *Pooling*.

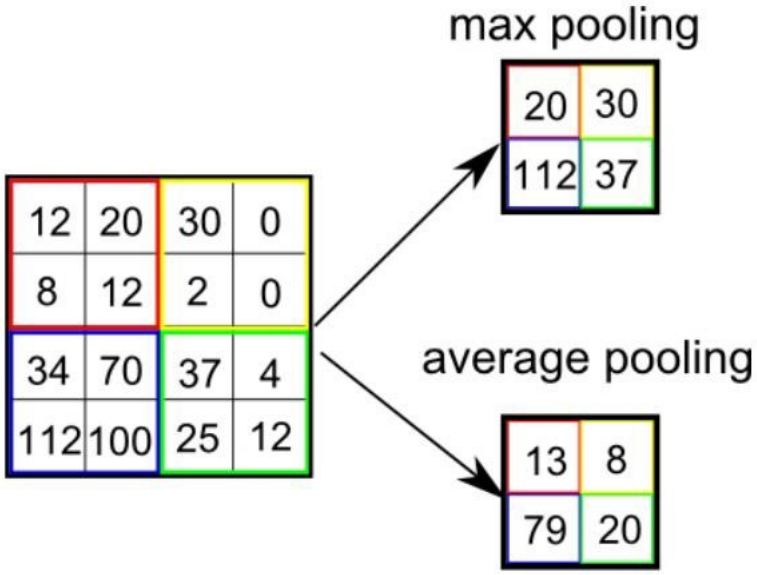

Fonte: <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>. Acesso em: 12 out. 2019.

2.4.2 *Auto-encoders*

Auto-encoders são algoritmos de compressão de dados que possuem certas características:

- São específicos para um tipo de dado, ou seja, um *auto-encoder* treinado com imagens só pode operar com imagens;
- A saída de um *auto-encoder* sempre terá um grau de degradação em relação à entrada;
- Aprendem automaticamente por exemplos, sem precisar da ajuda humana.

O principal uso de um *auto-encoder* é de aprender como comprimir dados em código e reconstruir os dados originais a partir do código com o mínimo de perda após a passagem dos dados por um gargalo: o espaço latente (LADJAL; NEWSON; PHAM, 2019).

O papel de um *auto-encoder* é realizar o papel de extração de características da entrada e também a reconstrução da entrada tendo apenas suas características.

A Figura 6 ilustra a estrutura básica de um *auto-encoder* onde a entrada é comprimida para sua representação no espaço latente e depois é reconstruída.

Figura 6 – Estrutura básica de *auto-encoder*.

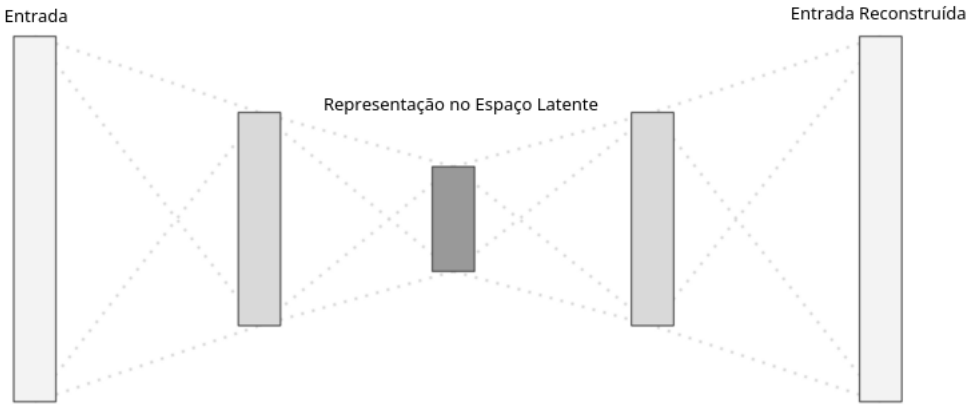

Fonte: <https://ai-odyssey.com/2017/02/07/autoencoders>. Acesso em: 12 out. 2019.

Um exemplo de uso de *auto-encoders* é Li et al. (2018) que recentemente desenvolveram *auto-encoders* que, após "aprenderem" a associar palavras escritas com vídeos e imagens, conseguem gerar vídeos curtos a partir de um texto dado.

3 Aplicações e soluções existentes

Aplicações que geram faces humanas realistas já existem, algumas inclusive permitem um certo nível de modificação nas faces que são geradas. As próximas seções apresentam duas dessas aplicações.

3.1 *This Person Does Not Exist*

É provavelmente o exemplo mais famoso de uma aplicação que gera faces humanas, foi implementada por Karras, Laine e Aila (2018)[1] utilizando uma técnica recente de aprendizado profundo: as Redes Adversárias Generativas (Generative Adversarial Network, GAN), onde o conceito básico é que duas RNAs competem entre si em um jogo (no sentido de Teoria dos Jogos) para aprenderem determinada tarefa. A Figura 7 ilustra exemplos de faces geradas pelo site.

Uma GAN funciona da seguinte forma: uma das redes (a rede geradora) gera candidatos e a outra rede (a rede discriminadora) as avalia. Inicialmente a rede discriminadora é treinada com um conjunto de dados até que alcance uma precisão aceitável e a rede geradora é treinada com um espaço latente pré determinado. A função do gerador é conseguir gerar imagens que consigam enganar o discriminador e uma função de retro propagação é aplicada em ambas as redes para que a rede geradora gere imagens melhores e a rede discriminadora melhore sua habilidade de avaliar se a imagem foi ou não gerada pela rede geradora (GOODFELLOW et al., 2014).

[1] Disponível em <https://thispersondoesnotexist.com/>.

Figura 7 – Exemplos de faces geradas pelo site This Person Does Not Exist.

Fonte: Karras, Laine e Aila (2018).

3.2 *Yearbook Face Editor*

Uma aplicação[2] desenvolvida pelo indivíduo identificado como CodeParade ou HackerPoet como *hobby*, utiliza o PCA diretamente no conjunto de dados de treinamento, sem passar pelos processos que foram utilizados no trabalho apresentado por esta monografia, possui um conjunto de dados de treinamento bem menor visto que este foi o anuário de escola do autor. Uma captura de tela da aplicação pode ser vista na Figura 8.

Figura 8 – Captura de tela do site *Yearbook Face Editor*.

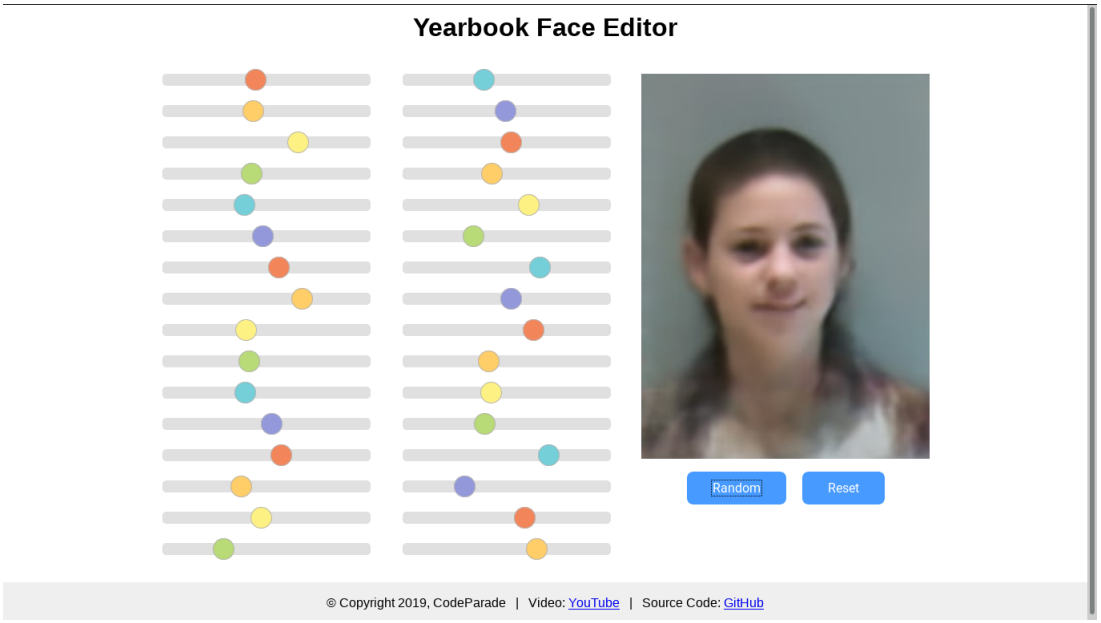

Fonte:<http://codeparade.net/faces/>. Acesso em: 12 out. 2019.

[2] Disponível em <http://codeparade.net/faces/>.

4 Materiais e métodos

Neste capítulo é mostrado qual base de dados foi utilizada como conjunto de treinamento e os métodos e tecnologias aplicados no desenvolvimento do trabalho.

4.1 Conjunto de Treinamento

Para a obtenção do conjunto de dados para a realização do treinamento da RNA foi feita uma análise de algumas bases de dados públicas pela Internet. Os critérios para a escolha foram a variação de pessoas nas bases de dados, o fato do nome da pessoa estar ou não associada à imagem e as imagens serem coloridas.

A seguir estão as bases e o veredito da escolha:

- ***Specs on Faces Dataset*(AFIFI; ABDELHAMED, 2019):** um conjunto de dados com 42592 imagens de 112 pessoas em diferentes condições de iluminação, posição e oclusão. Possui uma baixa variação de pessoas.
- ***Labeled Faces in the Wild Home*(HUANG et al., 2007):** este conjunto de dados possui mais de 13000 imagens de 1680 pessoas, todas as imagens possuem o nome da pessoa associada. Possui várias imagens de uma mesma pessoa, diminuindo a variação de faces no conjunto.
- ***Famous Birthdays*[1]:** não é um conjunto de dados formal, porém possui imagens de milhares de celebridades. Cada dia do ano mostra as 48 celebridades mais famosas nascidas no dia, para um potencial de $366 \times 48 = 17520$ imagens. Como cada celebridade aparece apenas uma vez, a variação de faces dentre as imagens é alta.
- **VGGFace2 (CAO et al., 2018):** conjunto com mais de 3,3 milhões de faces de mais de 9000 pessoas, é diferente dos outros conjuntos de dados pois este conjunto possui tanto imagens quanto modelos já treinados disponíveis para o uso. As imagens não possuem identificação da pessoa nela. Este conjunto também é notório por necessitar de uma alta capacidade computacional para ser utilizado.

A base de dados escolhida foi o site *Famous Birthdays* pela alta variação de pessoas nas imagens. Mesmo assim uma parte das imagens teve que ser descartada por não possuir uma face reconhecível pelo algoritmo de reconhecimento facial utilizado ou por ser em escala de cinzas, o que acarretaria em uma poluição do conjunto de treinamento.

[1] Disponível em <https://famousbirthdays.com>.

4.2 Função do *Auto-Encoder*, do *Encoder* e do PCA

O uso de um *auto-encoder* não é necessariamente indispensável porém sua utilização é interessante por dois motivos principais: o primeiro é que o *auto-encoder* realiza a redução da quantidade de dimensões da imagem para que o PCA não tenha que descartar muitas características e também para diminuir o custo de processamento do PCA (inclusive este é o motivo do porquê não foi utilizado o VGGFace2, notório por exigir muito poder computacional). O segundo motivo é que ao passar pelas camadas de convolução, a RNA passa a ter um conhecimento espacial de como os pixeis se relacionam um com os outros, adquirindo um senso de "vizinhança" para cada pixel. O segundo motivo torna possível a RNA entender mais facilmente características como a rotação da cabeça ou o tamanho do nariz, traços intrinsecamente espaciais e físicos da imagem.

O *auto-encoder* recebe como entrada uma imagem com 64 pixeis de largura, 64 pixeis de altura e 3 canais de cores - o que resulta em 12288 características - e as diminui para $4 \times 4 \times 240 = 3840$ características com pouca perda, mesclando as características originais, e dessas 3840 características são escolhidas 300 para a representação densa. Caso o PCA fosse aplicado diretamente nas imagens originais, quase 12000 características seriam descartadas, ao contrário de 3540, uma perda bem menor. A Figura 9 ilustra de forma simplificada o caminho percorrido pela imagem.

Figura 9 – Representação do *auto-encoder*.

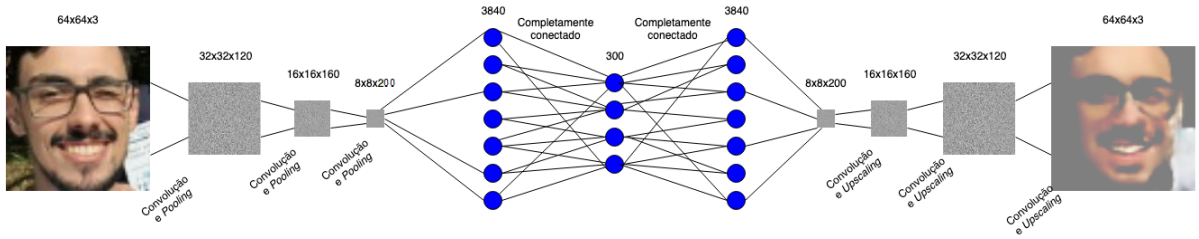

Fonte: Elaborada pelo autor.

Após o treinamento, o *auto-encoder* gera um modelo das faces que será utilizado por um encoder para gerar um vetor denso das imagens a partir do modelo. A Figura 10 mostra exemplos de imagens do conjunto de treinamento e sua saída gerada pelo modelo treinado pelo *auto-encoder*, observa-se a evolução do modelo em gerar saídas que melhor representam faces humanas.

Depois de gerado os vetores densos, o PCA é utilizado para obter os autovetores e autovalores.

Figura 10 – Imagens originais e a saída pelo modelo.

Modelo gerado na época 2 Modelo gerado na época 182000

Fonte: Elaborada pelo autor.

4.3 Gerador e Editor de Faces

A aplicação projetada e desenvolvida neste trabalho consiste em uma interface de usuário simples onde o usuário pode alterar posições em controles deslizáveis para alterar os valores que serão utilizados para o cálculo da imagem. Esses valores serão repassados para o *back-end* que realizará os cálculos em tempo real e retornará uma imagem reconstruída a partir dos valores.

A Figura 11 ilustra o funcionamento da aplicação. Primeiro o *back-end* da aplicação deve ser alimentado com os auto-valores e auto-vetores obtidos pela aplicação do PCA em todas as faces dado um modelo gerado pelo *auto-encoder*. Após a alimentação do *back-end* o uso se faz primariamente pela interface, onde o usuário pode alterar os parâmetros que serão repassados ao *back-end* que realizará uma multiplicação de cada parâmetro com seu respectivo auto-vetor e auto-valor e retornará à interface a imagem calculada.

A Figura 12 ilustra ações que o usuário pode realizar. As ações mais simples e que possivelmente serão as mais realizadas são: a de alterar os parâmetros para o cálculo da nova face, a de ir diretamente para uma face pré-carregada e a de salvar a imagem atual. Se o usuário quiser ele pode inserir novas faces ou até mesmo utilizar um conjunto de treinamento totalmente diferente e retreinar o *auto-encoder*, gerando um novo modelo e aplicar o PCA nesse novo modelo criado.

Figura 11 – Esquema de funcionamento da aplicação.

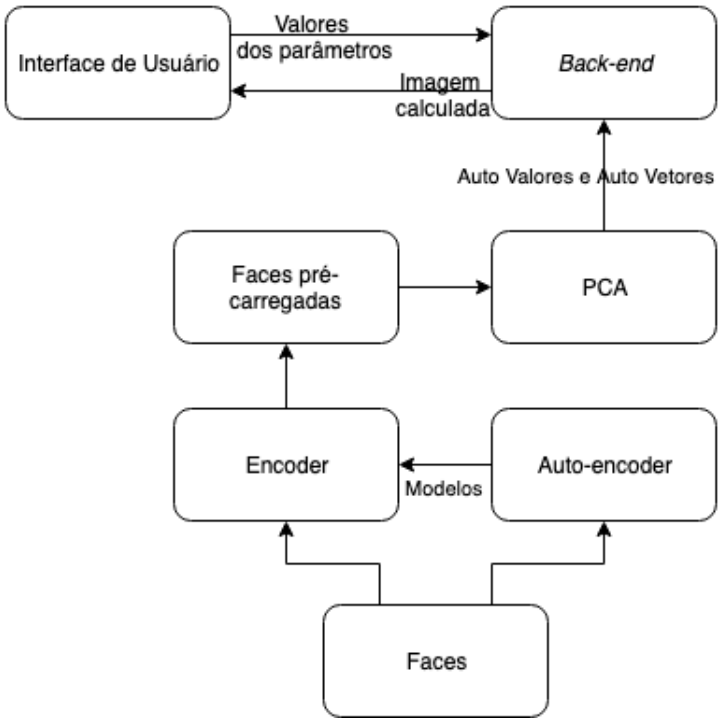

Fonte: Elaborada pelo autor.

Figura 12 – Casos de uso da aplicação.

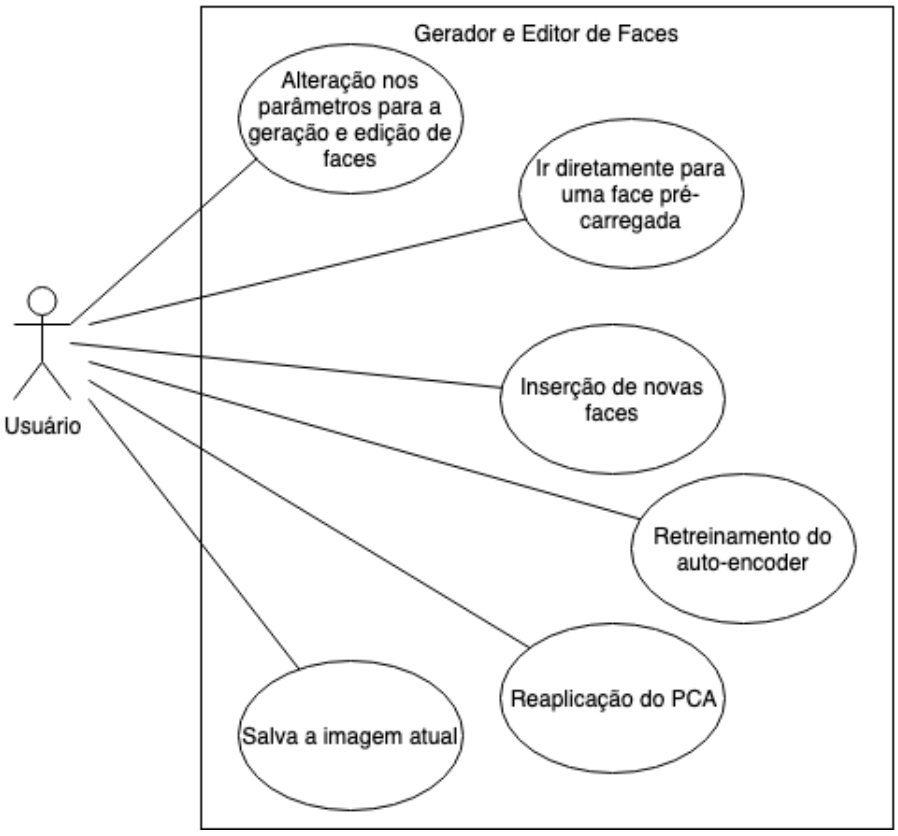

Fonte: Elaborada pelo autor.

4.4 Tecnologias Escolhidas

Para a implementação do trabalho optou-se pelo uso da linguagem Python3, a biblioteca *Face Recognition* para o reconhecimento de faces nas imagens, o TensorFlow como a plataforma para o treinamento do *auto-encoder* e a biblioteca PyGame para a criação da interface de usuário.

4.4.1 TensorFlow

TensorFlow (ABADI et al., 2015) é uma biblioteca de código aberto multiplataforma para computação numérica e ML utilizando grafos de fluxo de dados. Ele reúne uma gama de modelos e algoritmos de ML e aprendizado profundo e foi desenvolvido inicialmente pelo *Google Brain Team* da Google para uso interno, sendo lançado com a licença Apache 2.0 em novembro de 2015.

O TensorFlow é composto por uma base implementada na linguagem C++ por causa de seu desempenho e possui uma interface em Python por ser uma linguagem mais simples. Em cima dessa interface Python situam-se bibliotecas de alto nível, como bibliotecas de modelos comumente utilizados e seus componentes e sobre essas bibliotecas existem as interfaces de mais alto nível para simplificar a criação de modelos e RNAs como o Keras. A Figura 13 ilustra a estrutura hierárquica do TensorFlow.

Figura 13 – Estrutura hierárquica do TensorFlow.

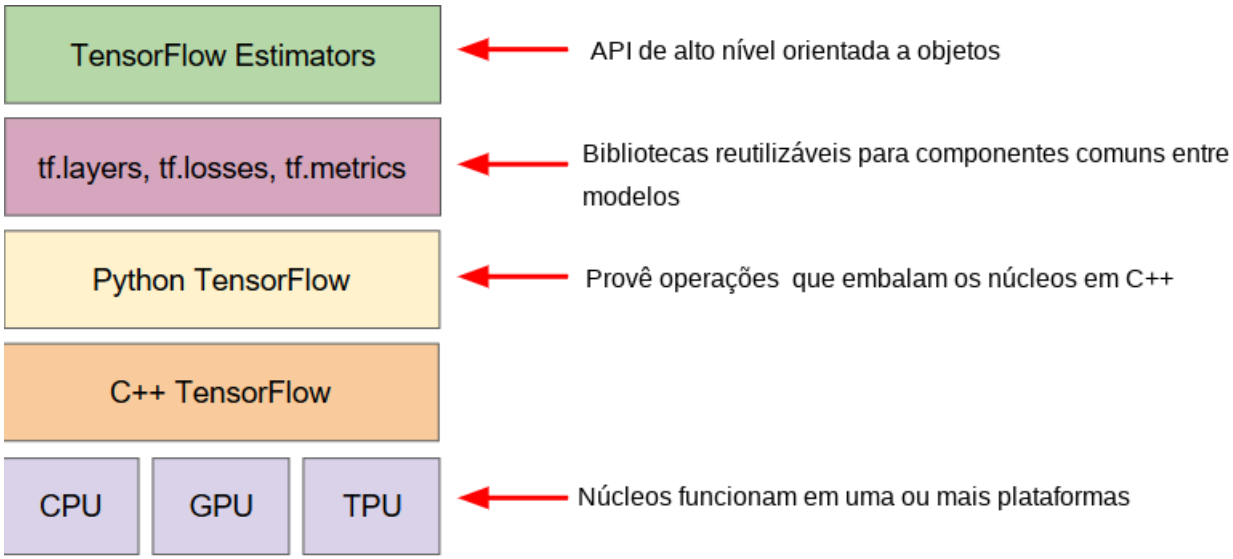

Fonte: Baseado em <https://developers.google.com/machine-learning/crash-course/first-steps-with-tensorflow/toolkit>. Acesso em: 12 out. 2019.

O funcionamento do TensorFlow se baseia na ideia de grafos, onde o usuário utiliza o TensorFlow para construir grafos onde em cada nó uma operação matemática é realizada e as

arestas são tensores comunicados entre os nós.

O maior benefício de utilizá-lo é a abstração que ele oferece para o processo de desenvolvimento de aplicações em ML, simplificando a implementação. Outro benefício é sua ampla comunidade e curva de aprendizado não-íngreme, alguns concorrentes como o *Microsoft Cognitive Toolkit* da Microsoft possui uma curva de aprendizado mais acentuada.

4.4.2 *Face Recognition*

Face Recognition[2] é uma biblioteca em código aberto de reconhecimento facial que não necessita do uso do TensorFlow, o que o torna mais leve e menos exigente de poder computacional.

Possui várias funcionalidades, desde a simples detecção de faces em uma imagem e suas posições até o reconhecimento de faces de uma mesma pessoa em diferentes imagens. A funcionalidade mais interessante a este trabalho é a de detecção de faces e suas posições na imagem.

[2] Disponível em <https://github.com/ageitgey/face_recognition>.

5 Desenvolvimento

Neste capítulo são apresentadass as etapas realizadas neste trabalhos: obtenção e tratamento da base de dados, a biblioteca de aprendizado de máquina em Python utilizada, a RNA implementada e a interface criada.

5.1 Tratamento do conjunto de treinamento

Por não ser um conjunto de dados formal, não existe uma uniformização nas imagens do *Famous Birthdays*, logo as imagens não são alinhadas com o rosto na vertical, necessitando uma normalização de todas as imagens recolhidas do site.

A obtenção da base de dados foi feita por meio de um rastreador de páginas que realizava o *download* apenas das imagens desejadas e já realizava o alinhamento das faces. Para definir se as imagens estavam ou não em escala de cinza foi utilizada uma função baseada nas equações apresentadas nas Equações 5.1 para calcular a saturação da imagem, onde R_{norm}, G_{norm} e B_{norm} são os valores normalizados dos canais R, G e B respectivamente, μ_R, μ_G e μ_B são as médias dos valores de cada canal, δ_R, δ_G e δ_B são os desvios padrões de cada canal e I_{sat} é o escore de saturação da imagem cujo caso valor for menor que 0,04 a imagem é considerada em escala de cinza e descartada. O Código 5.1 mostra a implementação na linguagem Python da função de saturação.

$$\begin{aligned} R_{norm} &= \frac{R - \mu_R}{\delta_R} \\ G_{norm} &= \frac{G - \mu_G}{\delta_G} \\ B_{norm} &= \frac{B - \mu_B}{\delta_B} \end{aligned} \tag{5.1}$$

$$I_{sat} = (R_{norm} - G_{norm})^2 + (R_{norm} - B_{norm})^2 + (G_{norm} - B_{norm})^2$$

No final 12095 imagens foram selecionadas. O tratamento realizado nas imagens foi a verticalização das faces: a imagem foi rotacionada para que o centro dos lábios e o centro do nariz estejam na mesma posição horizontal, os olhos em posições fixas determinadas no código e o redimensionamento das imagens de 300x300 para 64x64. A Figura 14 ilustra como a imagem antes e depois do tratamento.

Código 5.1 – Implementação da função de saturação

```
import numpy as np
import imageio
```

Figura 14 – Imagem antes (à esquerda) e depois (à direita) do tratamento.

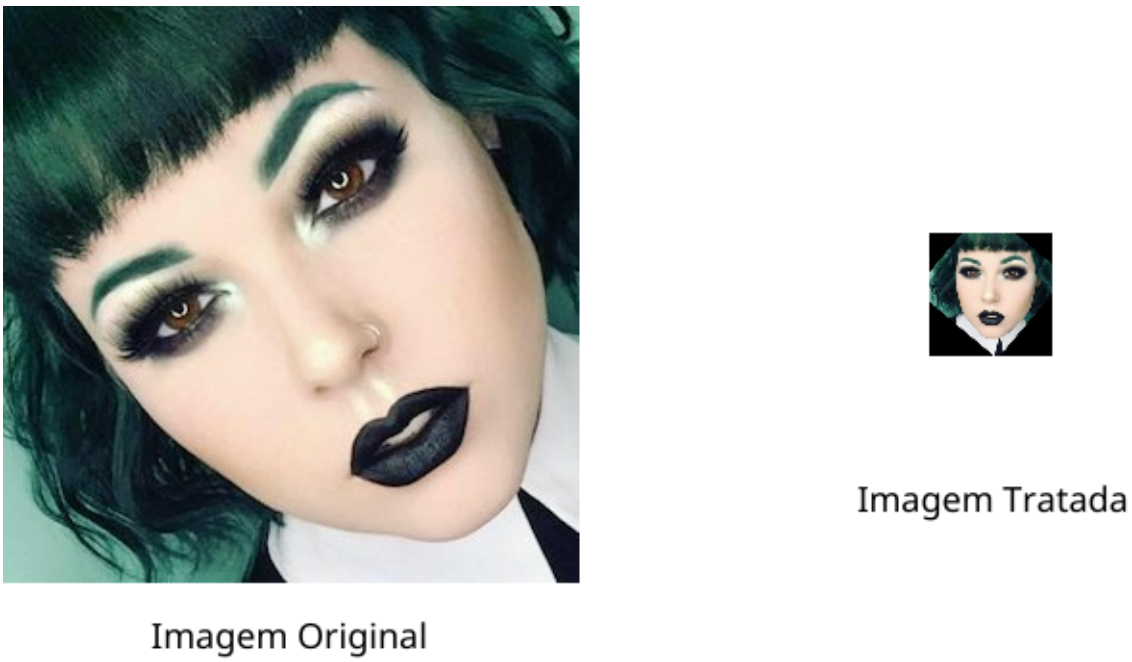

Fonte: Elaborada pelo autor.

```
def getNorm(a):
    return (a-np.mean(a))/np.std(a)

imgNumpy = imageio.imread("temp.png")
imgNumpy = np.asarray(imgNumpy)
cores = 0

nR = getNorm(imgNumpy[:,:,0])
nG = getNorm(imgNumpy[:,:,1])
nB = getNorm(imgNumpy[:,:,2])
cores = np.mean(np.square(nR-nG))+np.mean(np.square(nR-nB))+
        np.mean(np.square(nG-nB))
```

5.2 Desenvolvimento e treinamento do *Auto-Encoder*

Como dito nas Seções 4.1 e 4.2, não é necessário o uso de um *auto-encoder*, principalmente com a existência de modelos já treinados e bem utilizados disponibilizados pelo VGGFaces. Porém é interessante a RNA ter conhecimento da "vizinhança" entre os pixels e também é interessante a possibilidade de utilizar máquinas menos potentes (como a utilizada neste trabalho) pois nem todas as pessoas têm condições de adquirir computadores com alta capacidade de processamento devido aos elevados custos.

O *auto-encoder* foi treinado com lotes de duzentas imagens selecionadas aleatoriamente do conjunto de treinamento e cada lote representa uma época de treinamento. Inicialmente um modelo foi salvo a cada três épocas como *backup* porém a utilização de armazenamento se mostrou elevada, por isso optou-se por salvar um modelo como *backup* a cada 100 épocas. O *auto-encoder* foi treinado por 182000 épocas. Durante todo o processo de treinamento a taxa de perda flutuou entre 0.62 e 0.69.

5.3 Aplicando o *Encoder* e o PCA

Após o *auto-encoder* gerar o modelo após 182000 épocas durante aproximadamente 30 horas, o encoder utilizou este modelo para codificar todo o conjunto de treinamento em um vetor denso, é neste vetor denso que se encontram os dados das faces pré-carregadas. O vetor denso foi submetido ao PCA que obteve os autovetores e autovalores.

5.4 A aplicação final

As Figuras 15 e 16 mostram a interface da aplicação sendo utilizada para gerar faces. A aplicação possui uma interface de usuário simples,

5.4.1 Controles deslizáveis

Os controles deslizáveis à esquerda são a parte da aplicação responsável por modificar a imagem mostrada na interface. Cada controle deslizável corresponde a um dos trezentos componentes principais obtido pelo PCA, foram rotulados possíveis características até o trigésimo quinto componente. A imagem é recalculada a qualquer alteração da posição em qualquer um dos controles deslizáveis, passando uma sensação de "edição em tempo real" da imagem exibida.

Figura 15 – Interface da aplicação com a face média.

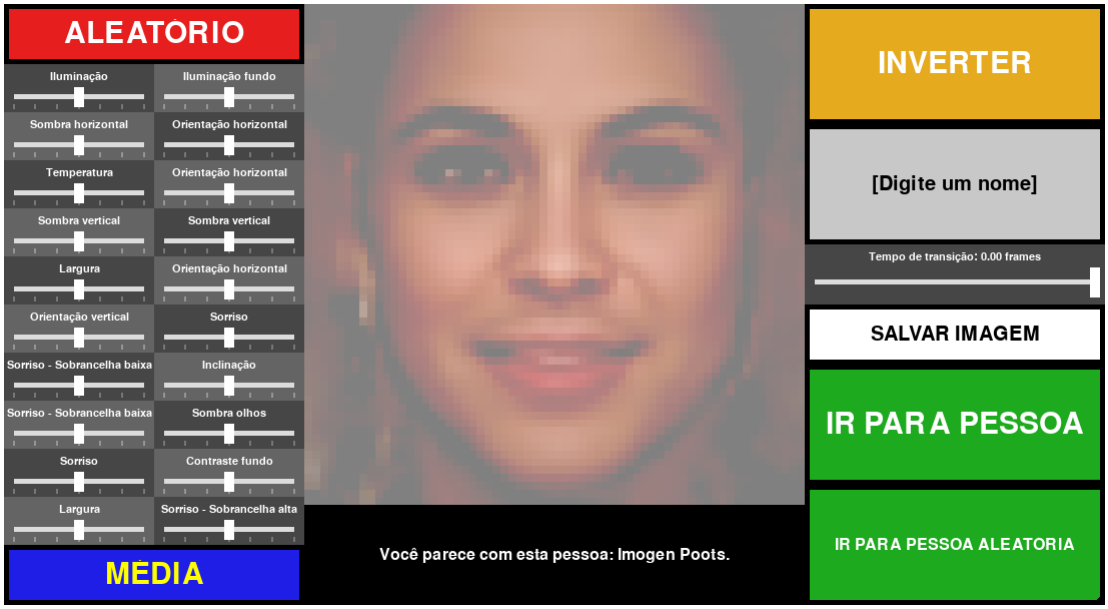

Fonte: Elaborada pelo autor.

Figura 16 – Interface da aplicação com uma face pré carregada.

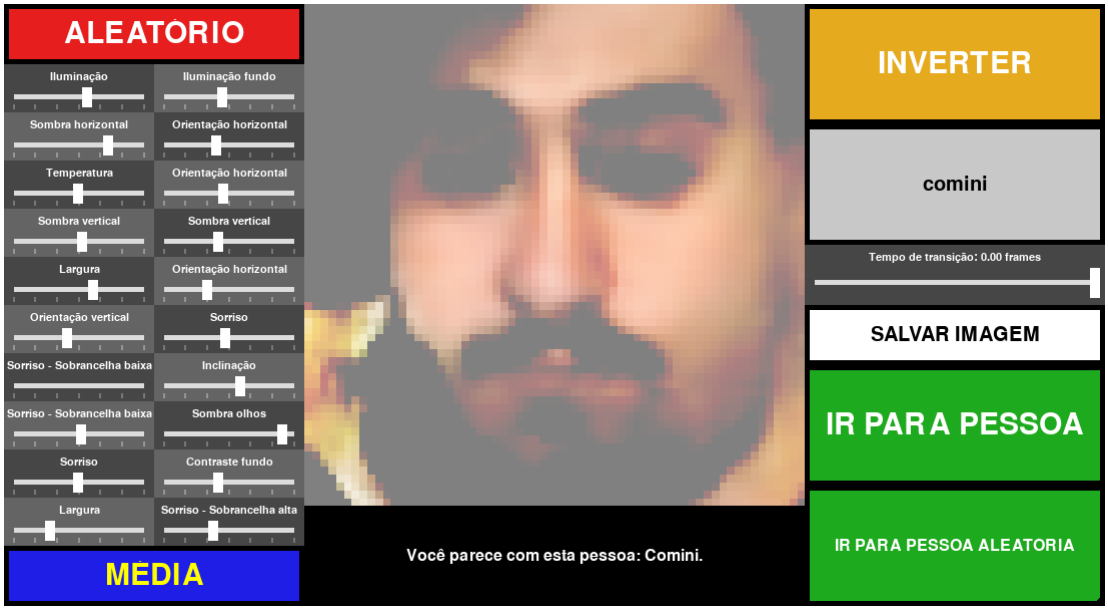

Fonte: Elaborada pelo autor.

O controle deslizável situado à direita é responsável por regular a quantidades de quadros que levará para uma face se transformar em outra após o botão "IR PARA PESSOA" ou "IR PARA PESSOA ALEATÓRIA" ser pressionado. Supõe-se que um segundo corresponda a sessenta quadros.

5.4.2 Botões e Caixa de Texto

Existem alguns botões na interface que realizam diferentes operações se pressionados:

- **ALEATÓRIO:** Atribui valores aleatórios baseados em uma distribuição normal a cada um dos controles deslizáveis;
- **MÉDIA:** Atribui zero para cada um dos controles deslizáveis;
- **INVERTER:** Multiplica cada controle deslizável por -1;
- **Digite um nome:** Ativa uma caixa de texto onde é possível inserir o nome de uma pessoa;
- **SALVAR:** Salva a imagem exibida atualmente no diretório "/imagensSalvas/imgSalva.png";
- **IR PARA PESSOA:** Caso o nome da pessoa inserida na caixa de texto "Digite um nome" exista no conjunto de faces pré-carregadas, os controles deslizáveis se ajustaram até terem os valores de cada componente referentes à pessoa;
- **IR PARA PESSOA ALEATÓRIA:** Similar ao botão anterior porém uma pessoa do conjunto de faces pré-carregadas é aleatoriamente selecionada.

A caixa de texto situada logo abaixo à imagem exibida mostra a pessoa entre as faces pré-carregadas mais "parecida" com a disposição atual dos controles deslizáveis. Essa pessoa mais parecida é calculada a partir de uma simples distância euclidiana dos valores atuais com os valores das faces pré-carregadas, retornando a pessoa a menor distância.

5.5 Inserção de novas faces

A inserção de novas faces ao conjunto de faces pré-carregadas é realizada por um código a parte para simplificar e modularizar melhor cada tarefa deste trabalho. A imagem deve inicialmente ser tratada para atender os requisitos da aplicação (a exemplo da Figura 14) pelo código em "AlinhadorQualquer.py" e depois codificado junto ao conjunto de faces pré-carregadas pelo código em "EncoderQualquer.py". Este último código retornará um novo vetor denso com as novas faces adicionadas que deverá ser carregado pela aplicação principal.

5.6 Passo a Passo

Para facilitar o uso de algum usuário que desejar utilizar a aplicação do zero, um breve passo-a-passo é disponibilizado a seguir:

1. **Obtenção do banco de dados:** Fica à critério do usuário. Caso utilize o mesmo banco utilizado neste trabalho (o site *Famous Birthdays*) o código em "PegaFaces.py" já realiza a obtenção e o tratamento das imagens;
2. **Tratamento do banco de dados:** O código em "AlinhadorQualquer.py" realiza esta tarefa. Caso utilize o mesmo banco utilizado neste trabalho o código em "PegaFaces.py" já realiza o tratamento nas imagens;
3. **Geração do modelo:** O código em "AutoEncoder.py" é responsável por esta tarefa, inicialmente ele salva modelos como *backups* a cada três épocas;
4. **Codificação:** A etapa que gera o vetor denso com todas as imagens é realizada pelo "Encoder.py";
5. **PCA:** Etapa que obtém os auto-valores e auto-vetores é realizada pelo adequadamente denominado "PCA.py".

6 Teste e Validação

6.1 Testes

Os primeiros testes realizados foram relacionados às ferramentas utilizadas para habituação com elas. Testes simples com a biblioteca *Face Recognition* e com a plataforma TensorFlow.

O teste subsequente foi o teste realizado para definir qual a profundidade do *auto-encoder*, quantas camadas ele deve ter de codificação e de decodificação.

Inicialmente foi testado um *auto-encoder* simples, com apenas uma camada oculta, isto foi devido ao uso da mentalidade da "Navalha de Occam": geralmente as ideias mais simples são as mais adequadas como solução de problemas. Depois de cerca de cinco mil épocas de treinamento a qualidade dos modelos não foi satisfatória, o que levou à adição de mais uma camada de codificação e uma camada de decodificação ao *auto-encoder*. Este processo se repetiu até que quatro camadas de codificação e quatro de decodificação resultaram em modelos satisfatórios.

O teste final foi já na aplicação quase finalizada, onde foi necessária a utilização da aplicação para poder rotular os controles deslizáveis com as possíveis características que elas alteram.

6.2 Validação

A validação deste trabalho foi mais qualitativa: a aplicação foi mostrada a colegas de turma e amigos que puderam utilizá-la.

Foi observado que ao atribuir valores próximos às extremidades em vários controles deslizáveis as faces se tornavam muito distorcidas, algumas vezes não era possível reconhecer uma face na imagem, porém caso a atribuição seja de valores que se assemelham à uma distribuição normal, as faces geradas são mais reconhecíveis e realistas. A Figura 17 apresenta algumas faces geradas pela aplicação por meio do botão "ALEATÓRIO".

Figura 17 – Exemplos de faces geradas por meio do botão “ALEATÓRIO” da aplicação.

Fonte: Elaborada pelo autor.

7 Conclusão

Este trabalho teve como objetivo o desenvolvimento de uma aplicação leve que pudesse gerar e editar faces humanas. Para realizar tal feito foram utilizado técnicas de aprendizado de máquina e de estatística, necessitando um estudo sobre os campos envolvidos e alguns campos além para a certificação de que foi estudado o necessário. Para isso foram utilizados livros, artigos e documentação de ferramentas para o desenvolvimento, como o TensorFlow e a linguagem Python.

A aplicação final obteve sucesso em gerar e editar faces a partir do conjunto de treinamento e com algumas observações interessantes, como o fato de que vários componentes obtidos pelo PCA são responsáveis por alterar o sorriso nas faces, alguns alterando a sobrancelha, outros não. Ressalta-se o fato de que a máquina "aprendeu" isso sozinha, que existe uma relação entre o sorriso de uma pessoa com a posição de suas sobrancelhas, a partir de números.

Também foi alcançado o objetivo da aplicação ser leve, visto que todo o processo de desenvolvimento, treinamento e utilização foi realizado em um computador comum, com um processador Intel i5, sem placa de vídeo dedicada e com oito gigabytes de memória RAM.

No entanto é possível perceber uma certa quantidade de ruído nas imagens reconstruídas causados pela redução de características para apenas 300, além das baixas dimensões das imagens (64x64 pixels) pelo fato de o treinamento do *auto-encoder* com imagens maiores exigiria um maior poder computacional, certamente as imagens seriam mais interessantes para o usuário se estivessem em uma resolução maior.

7.1 Trabalhos Futuros

Para trabalhos futuros pode-se sugerir o uso do VGGFace que por motivos destacados na Seção 4.2 não pôde ser utilizado neste trabalho, a implementação deste mesmo trabalho porém sem a utilização de um *auto-encoder* também pode vir a ser interessante, possivelmente com resultados parecidos só que com mais ruído no momento da reconstrução das faces. Também pode ser interessante realizar trabalhos similares a este utilizando uma GAN, visto que no momento as GANs apenas geram as imagens sem poder editá-las depois.

Outra sugestão é utilizar imagens maiores para o treinamento do *auto-encoder* juntamente com um aumento de características no espaço latente, melhorando a resolução e qualidade das imagens reconstruídas.

Referências

ABADI, M.; AGARWAL, A.; BARHAM, P.; BREVDO, E.; CHEN, Z.; CITRO, C.; CORRADO, G. S.; DAVIS, A.; DEAN, J.; DEVIN, M.; GHEMAWAT, S.; GOODFELLOW, I.; HARP, A.; IRVING, G.; ISARD, M.; JIA, Y.; JOZEFOWICZ, R.; KAISER, L.; KUDLUR, M.; LEVENBERG, J.; MANé, D.; MONGA, R.; MOORE, S.; MURRAY, D.; OLAH, C.; SCHUSTER, M.; SHLENS, J.; STEINER, B.; SUTSKEVER, I.; TALWAR, K.; TUCKER, P.; VANHOUCKE, V.; VASUDEVAN, V.; VIéGAS, F.; VINYALS, O.; WARDEN, P.; WATTENBERG, M.; WICKE, M.; YU, Y.; ZHENG, X. *TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems*. 2015. Software available from tensorflow.org. Disponível em: <https://www.tensorflow.org/>. Acesso em: 28 out. 2019.

AFIFI, M.; ABDELHAMED, A. Afif4: Deep gender classification based on adaboost-based fusion of isolated facial features and foggy faces. *Journal of Visual Communication and Image Representation*, Elsevier, 2019. Disponível em: <https://arxiv.org/abs/1706.04277>. Acesso em: 12 out. 2019.

ALPAYDIN, E. *Introduction to Machine Learning*. [s.n.], 2009. Disponível em: <https://books.google.com.br/books?hl=pt-BR&lr=&id=TtrxCwAAQBAJ&oi=fnd&pg=PR7&dq=machine+learning+introduction&ots=T5elKJ-7rR&sig=PSu1GHskI1jQwvBmce_4mdecQc4#v=onepage&q=introduction&f=false>. Acesso em: 02 out. 2019.

BUDUMA, N. *Fundamentals of Deep Learning*. [S.l.]: O'Riley Media, Inc, 2017. ISBN 978-1-491-92561-4.

CAO, Q.; SHEN, L.; XIE, W.; PARKHI, O. M.; ZISSERMAN, A. Vggface2: A dataset for recognising face across pose and age. *International Conference on Automatic Face and Gesture Recognition*, 2018.

DOERSCH, C. Tutorial on variational autoencoders. 2016. Disponível em: <https://arxiv.org/abs/1606.05908>. Acesso em: 20 mar. 2019.

GONZALEZ, R. C.; WOODS, R. E. *Digital Image Processing*. [S.l.]: Pearson Education Inc., 2008.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. MIT Press, 2016. Disponível em: <http://www.deeplearningbook.org>. Acesso em: 12 out. 2019.

GOODFELLOW, I.; POUGET-ABADIE, J.; MIRZA, M.; XU, B.; WARDE-FARLEY, D.; OZAIR, S. Generative adversarial nets. *Neural Information Processing Systems Conference*, 2014. Disponível em: <https://papers.nips.cc/paper/5423-generative-adversarial-nets.pdf>. Acesso em: 02 out. 2019.

HUANG, G. B.; RAMESH, M.; BERG, T.; LEARNED-MILLER, E. *Labeled Faces in the Wild: A Database for Studying Face Recognition in Unconstrained Environments*. [S.l.], 2007. Disponível em: <http://vis-www.cs.umass.edu/lfw/>. Acesso em: 12 out. 2019.

KARN, U. *A Quick Introduction to Neural Networks*. 2016. Disponível em: <https://ujjwalkarn.me/2016/08/09/quick-intro-neural-networks>. Acesso em: 11 mar. 2019.

KARRAS, T.; LAINE, S.; AILA, T. A style-based generator architecture for generative adversarial networks. *CoRR*, abs/1812.04948, 2018. Disponível em: <http://arxiv.org/abs/1812.04948>. Acesso em: 11 mar. 2019.

LADJAL, S.; NEWSON, A.; PHAM, C. A pca-like autoencoder. *CoRR*, abs/1904.01277, 2019. Disponível em: <http://arxiv.org/abs/1904.01277>. Acesso em: 12 out. 2019.

LI, Y.; MIN, M. R.; SHEN, D.; CARLSON, D.; CARIN, L. Video generation from text. 2018. Disponível em: <https://www.aaai.org/GuideBook2018/16152-72279-GB.pdf>. Acesso em: 11 mar. 2019.

RUSSELL, S. J.; NORVIG, P. *Artificial Intelligence: A Modern Approach*. 3. ed. [S.l.]: Prentice Hall, 2009.

WOLD, S.; ESBENSEN, K.; GELADI, P. Principal component analysis. *Chemometrics and intelligent laboratory systems*, Elsevier, v. 2, n. 1-3, p. 37–52, 1987. Disponível em: <http://pzs.dstu.dp.ua/DataMining/pca/bibl/Principal\%20components%20analysis.pdf>. Acesso em: 12 out. 2019.