



**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE ENGENHARIA ELÉTRICA E INFORMÁTICA
CURSO DE BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO**

HIAGO WILLYAM ARAÚJO LACERDA

**SISTEMA AUTOMÁTICO MÓVEL PARA GESTÃO DE
PRESENÇA COM RECONHECIMENTO FACIAL**

CAMPINA GRANDE - PB

2024

HIAGO WILLYAM ARAÚJO LACERDA

**SISTEMA AUTOMÁTICO MÓVEL PARA GESTÃO DE
PRESENÇA COM RECONHECIMENTO FACIAL**

**Trabalho de Conclusão Curso
apresentado ao Curso Bacharelado em
Ciência da Computação do Centro de
Engenharia Elétrica e Informática da
Universidade Federal de Campina
Grande, como requisito parcial para
obtenção do título de Bacharel em
Ciência da Computação.**

Orientadora : Joseana Macêdo Fachine Régis de Araújo

CAMPINA GRANDE - PB

2024

HIAGO WILLYAM ARAÚJO LACERDA

**SISTEMA AUTOMÁTICO MÓVEL PARA GESTÃO DE
PRESENÇA COM RECONHECIMENTO FACIAL**

**Trabalho de Conclusão Curso
apresentado ao Curso Bacharelado em
Ciência da Computação do Centro de
Engenharia Elétrica e Informática da
Universidade Federal de Campina
Grande, como requisito parcial para
obtenção do título de Bacharel em
Ciência da Computação.**

BANCA EXAMINADORA:

**Joseana Macêdo Fechine Régis de Araújo
Orientador – UASC/CEEI/UFCG**

**Adalberto Cajueiro de Farias
Examinador – UASC/CEEI/UFCG**

**Francisco Vilar Brasileiro
Professor da Disciplina TCC – UASC/CEEI/UFCG**

Trabalho aprovado em: 17 de maio de 2024.

CAMPINA GRANDE - PB

RESUMO

Diante da dinâmica evolução tecnológica que permeia nossa sociedade contemporânea, a interseção entre inovação e segurança tem se tornado um terreno fértil para a discussão de temas candentes, como é o caso do reconhecimento facial. Esse avanço tecnológico, que se destaca pela sua capacidade de identificar e autenticar pessoas por meio de características faciais únicas, tem atraído considerável atenção tanto do meio acadêmico quanto do público em geral, tornando-se um tema de interesse em discussões sobre privacidade, segurança e eficácia. Nesse contexto de amplo debate, o objetivo do trabalho ora descrito é o desenvolvimento de um sistema móvel para gerenciamento de presença baseado em reconhecimento facial. São abordados os aspectos técnicos de design e estratégias, incluindo seleção de algoritmos e arquitetura de sistemas. Especificamente, o modelo de autenticação facial será construído a partir de fotos de qualidade mediana, capturadas por uma câmera frontal convencional. Além disso, será desenvolvido um aplicativo móvel que utilize este modelo para gerenciar a presença em sala de aula. A pesquisa contribuirá com insights sobre as dimensões técnicas e éticas da integração do reconhecimento facial para registro de presença, oferecendo orientação para implementações futuras neste campo.

AUTOMATIC MOBILE SYSTEM FOR ATTENDANCE MANAGEMENT WITH FACIAL RECOGNITION

ABSTRACT

In the face of the dynamic technological evolution that permeates our contemporary society, the intersection of innovation and security has become a fertile ground for the discussion of pressing topics, such as facial recognition. This technological advancement, notable for its ability to identify and authenticate individuals through unique facial features, has garnered considerable attention from both academia and the general public, becoming a topic of interest in discussions on privacy, security, and effectiveness. In this context of extensive debate, the objective of the present work is the development of a mobile system for attendance management based on facial recognition. The study addresses the technical aspects of design and strategies, including algorithm selection and system architecture. Specifically, the facial authentication model will be constructed from medium-quality photos captured by a conventional front-facing camera. Additionally, a mobile application will be developed to utilize this model for managing classroom attendance. The research will contribute insights into the technical and ethical dimensions of integrating facial recognition for attendance recording, providing guidance for future implementations in this field.

SISTEMA AUTOMÁTICO MÓVEL PARA GESTÃO DE PRESENÇA COM RECONHECIMENTO FACIAL

Hiago Willyam Araújo Lacerda
Unidade Acadêmica de Sistemas e Computação
Universidade Federal de Campina Grande
Campina Grande, Paraíba, Brasil
hiago.lacerda@ccc.ufcg.edu.br

Joseana Macêdo Fechine Régis de Araújo
Unidade Acadêmica de Sistemas e Computação
Universidade Federal de Campina Grande
Campina Grande, Paraíba, Brasil
joseana@computacao.ufcg.edu.br

RESUMO

Diante da evolução tecnológica que permeia a sociedade contemporânea, a interseção entre inovação e segurança tem se tornado um terreno fértil para a discussão de temas candentes, como é o caso do reconhecimento facial. Esse avanço tecnológico, que se destaca pela sua capacidade de identificar e autenticar pessoas por meio de características faciais únicas, tem atraído atenção considerável, tanto do meio acadêmico quanto do público em geral, tornando-se um tema de interesse em discussões sobre privacidade, segurança e eficácia. Nesse contexto de amplo debate, o objetivo do trabalho ora descrito é o desenvolvimento de um sistema móvel para gerenciamento de presença baseado em reconhecimento facial. Para tanto, são abordados os aspectos técnicos de design e estratégias, incluindo seleção de modelos e respectivos algoritmos e arquitetura de sistemas. Especificamente, o modelo de autenticação facial foi treinado e testado a partir de fotos de face, de qualidade mediana, capturadas por uma câmera convencional de *smartphone*. Além disso, foi desenvolvido um aplicativo móvel que utiliza o modelo para gerenciar a presença de pessoas em um ambiente (p.ex.: em sala de aula). Diante da metodologia de avaliação adotada e dos resultados obtidos, a pesquisa contribuirá com *insights* sobre as dimensões técnicas e éticas da integração do reconhecimento facial para registro de presença, oferecendo orientação para implementações futuras neste contexto.

Palavras-Chave

Controle de acesso automatizado. Segurança biométrica. Reconhecimento facial.

1. INTRODUÇÃO

A gestão eficaz da presença e da participação de pessoas em grandes grupos, representa um desafio significativo que consome recursos valiosos de tempo e esforço, especialmente quando feito manualmente. Além disso, os métodos tradicionais de controle de acesso, como senhas, cartões ou chaves, podem causar problemas para seus usuários, uma vez que estão sujeitos à perda, a roubo e até a esquecimento, tornando-se não apenas um obstáculo para sua adesão, mas também um item comprometedor para a segurança. Por outro lado, as características biológicas do indivíduo não estão sujeitas a essas vulnerabilidades.

Isso ressalta a importância e a viabilidade da automação do controle de acesso e da autenticação individual, fazendo uso de características biológicas, como o reconhecimento facial, que oferece vantagens claras em comparação com os métodos tradicionais de acesso [1].

Até meados dos anos 90, as técnicas de reconhecimento facial eram relativamente simples, focadas principalmente na identificação de uma única face em fundos simples ou complexos [2].

O avanço dessas técnicas foi impulsionado pelo crescimento exponencial do poder computacional, possibilitando o estabelecimento de um novo paradigma na identificação e autenticação de pessoas em diversos contextos. Esses avanços permitiram não apenas identificar faces em diferentes condições ambientais, mas também realizar análises mais sofisticadas, como reconhecimento de expressões faciais e até mesmo identificação em tempo real em vídeos com movimento.

Neste cenário de avanços tecnológicos contínuos, é essencial explorar soluções inovadoras que ofereçam conveniência, especialmente considerando a ubiquidade crescente e o aprimoramento contínuo dos dispositivos móveis. A integração do reconhecimento facial em *smartphones* representa uma oportunidade única para aprimorar a segurança e a usabilidade. Entretanto, é importante considerar que os sistemas de biometria facial baseados em *smartphones* enfrentam desafios específicos que podem limitar sua eficácia. Além dos problemas comuns, como variações de iluminação, oclusões e mudanças de pose, esses sistemas são impactados por diversos fatores adicionais, tais como: (i) baixa qualidade da imagem, (ii) poder computacional limitado e (iii) memória limitada [3].

Sendo assim, o propósito central do trabalho é o desenvolvimento de um aplicativo móvel, que integre um sistema de gestão de presença, baseado em autenticação facial. A motivação para a pesquisa parte da possibilidade de oferecer uma contribuição para a eficiência e o aprimoramento da segurança no controle de presença em grupos, capitalizando as inovações tecnológicas mais recentes no campo do reconhecimento facial e da computação móvel. No trabalho, também foram abordados os aspectos técnicos essenciais, concentrando-se na seleção de modelos, algoritmos e arquiteturas apropriadas, com o objetivo de superar os desafios e limitações de hardware associados ao reconhecimento facial em *smartphones*.

As demais seções do presente documento estão organizadas conforme descrição a seguir. Na Seção 2, serão abordados sistemas de reconhecimento facial aplicados em contextos similares, com análise de suas contribuições e abordagens. Na Seção 3, serão explorados os conceitos essenciais sobre o reconhecimento facial, incluindo técnicas de verificação e identificação, bem como estratégias de detecção facial e o uso de transferência de conhecimento. Em seguida, na Seção 4, detalha-se as etapas seguidas para o desenvolvimento da solução, incluindo a aquisição e o pré-processamento dos dados, a definição e treinamento do modelo e o desenvolvimento do aplicativo móvel, com descrição dos componentes do *backend* e do *frontend*. Na Seção 5, são apresentados e discutidos os resultados obtidos. Por fim, na Seção 6, destaca-se as principais conclusões do estudo, incluindo lições aprendidas, limitações e sugestões para trabalhos futuros.

2. TRABALHOS RELACIONADOS

O desenvolvimento de sistemas de controle de presença baseados em reconhecimento facial é uma área de pesquisa dinâmica, com diversas abordagens e técnicas sendo exploradas para melhorar a precisão e eficiência desses sistemas.

Khan, Akram e Usman [4] apresentaram um sistema de controle de presença em tempo real que combina detecção de faces utilizando YOLO V3 e reconhecimento facial por meio do Microsoft Azure Face API. Esse trabalho destaca a integração de algoritmos avançados de visão computacional para automatizar a marcação de presença em salas de aula, oferecendo uma solução eficaz e precisa.

Sunaryono, Siswanto e Anggoro [5] propuseram um sistema baseado em Android para controle de presença, a partir do qual os estudantes capturavam imagens de suas faces e de um código QR exibido na sala de aula utilizando *smartphones*. Essas imagens eram então processadas em um servidor para verificar a presença dos alunos. Esse estudo demonstra a aplicação prática de tecnologia móvel na automatização de processos de marcação de presença, contribuindo para a eficiência e praticidade na gestão acadêmica.

Além disso, Chinimilli, Kaipu, T, Kotturi e Mandapati [6] investigaram um sistema de controle de presença baseado em reconhecimento facial utilizando o algoritmo Haar Cascade e o Local Binary Pattern Histogram (LBPH). Este trabalho enfatizou a importância da escolha adequada do algoritmo de reconhecimento facial para lidar com desafios como variações de iluminação e o uso de acessórios pelos alunos. O LBPH se mostrou uma escolha eficaz em relação a outros métodos devido à sua robustez e capacidade de lidar com transformações monotônicas de escala de cinza.

3. FUNDAMENTAÇÃO TEÓRICA

Nesta seção, serão discutidos os conceitos fundamentais para compreensão da temática abordada no trabalho. A discussão envolve o desenvolvimento de um modelo para reconhecimento facial, com atenção especial dada às estratégias para detecção facial e à transferência de conhecimento aplicada a um modelo pré-treinado.

3.1 Reconhecimento Facial

Reconhecer um indivíduo com base em suas características faciais pode ser uma tarefa fácil para os humanos no dia a dia. Porém, torna-se complexo quando aplicado no contexto digital utilizando tecnologias como visão computacional e reconhecimento de padrões [7].

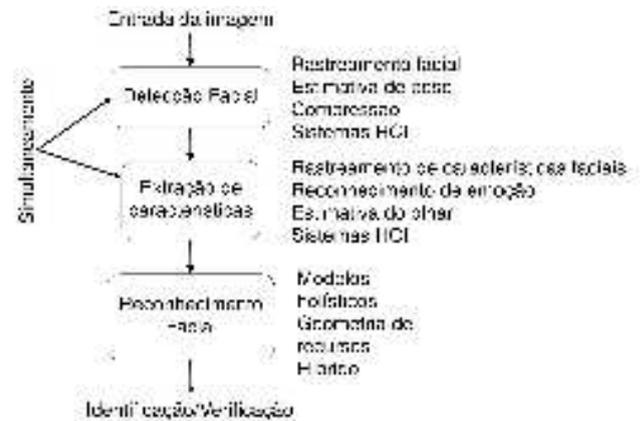
O processo de reconhecimento facial envolve comparar uma imagem de entrada de uma face (ou características de uma face) com um modelo (ou conjunto de modelos) de face(s) (ou características de face(s)) conhecida(s) para determinar se há uma correspondência. Nesse contexto, os sistemas biométricos de reconhecimento facial podem operar em dois modos distintos, descritos a seguir (Figura 2) [2].

- **Verificação:** o sistema verifica se os dados biométricos correspondem à identidade reivindicada pelo indivíduo. Esse processo é às vezes chamado de autenticação facial (*face authentication*).
- **Identificação:** o sistema busca encontrar uma correspondência nas características biométricas em toda a base de conhecimento para identificar uma face.

O problema de identificação é mais complexo que o de verificação, pois, além de garantir a mesma acurácia exigida na verificação, deve percorrer toda a base de conhecimento e fazer a

identificação, o que torna o tempo de resposta um problema a ser tratado [2].

Figura 2: Configuração de um sistema de reconhecimento facial genérico.



Fonte: Adaptado de [2].

No entanto, como ilustrado na Figura 2, independente do modo, o processo de reconhecimento de faces é descrito em três etapas principais: captura das faces, extração de características, construção dos padrões e identificação ou verificação. As características faciais (como olhos, nariz e boca) são cruciais, tanto para a detecção quanto para o reconhecimento facial [2].

3.2 Detecção Facial

Para a detecção facial neste trabalho, foram exploradas duas técnicas distintas: o Classificador em Cascata de Haar (*Haar Cascade Classifier*) e as Redes Neurais Convolucionais (*Convolutional Neural Network*).

O Classificador em Cascata de Haar é um *framework* de detecção rápida de objetos, que utiliza uma abordagem eficiente com a integral da imagem, técnica que permite o cálculo rápido de somas retangulares de pixels em uma área específica da imagem, e um algoritmo baseado em AdaBoost para identificar características críticas em imagens, aplicando uma cascata de classificadores para focar em regiões promissoras. Esse classificador foi proposto no início do século XXI por Paul Viola e Michael Jones [7].

As Redes Neurais Convolucionais foram introduzidas pela arquitetura *LeNet* e ganharam destaque com a *AlexNet*. Essa rede neural utiliza a convolução em suas camadas e inclui outras técnicas como *padding*, funções de ativação, *pooling*, *dropout* e camadas densas para melhorar o desempenho em tarefas de reconhecimento e classificação de padrões [7].

3.3 Transferência de Conhecimento

A transferência de conhecimento (*transfer learning*) em Machine Learning refere-se à capacidade de utilizar o conhecimento adquirido em uma tarefa para melhorar o desempenho em outra tarefa relacionada. Isso envolve reutilizar partes de um modelo pré-treinado em uma nova tarefa ou domínio, em vez de treinar totalmente um modelo para cada nova aplicação [8].

4. PROJETO DO SISTEMA

Nesta seção, será descrita a metodologia adotada para o desenvolvimento da solução. Inicialmente, procedeu-se à busca da base de dados, seguida do desenvolvimento do modelo e, por fim, do desenvolvimento do aplicativo móvel.

O desenvolvimento do modelo para o reconhecimento facial, seguiu as seguintes etapas:

1. Carregamento e pré-processamento das imagens da base de dados adquirida;
2. Definição e treinamento do modelo de reconhecimento facial utilizando transferência de conhecimento com MobileNet; e
3. Avaliação do modelo usando validação cruzada e métricas de desempenho;

Para expandir o modelo e incluir novas identidades no sistema, o processo envolveu as seguintes etapas:

1. Detecção de rosto na imagem de entrada usando o classificador em cascata de Haar;
2. Pré-processamento da região do rosto detectado; e
3. Aplicação do modelo treinado para prever a identidade da pessoa na imagem.

O Modelo foi desenvolvido utilizando a Linguagem *Python* e fez uso das bibliotecas a seguir.

- *TensorFlow* e *Keras* - utilizadas para definição e treinamento de redes neurais convolucionais, incluindo *transfer learning* com MobileNet, para reconhecimento facial.
- *OpenCV* - empregada para processamento de imagens, especialmente detecção de rosto utilizando o classificador em cascata de Haar.
- *Matplotlib* e *Seaborn* - utilizadas para visualização de dados, obtenção de métricas de desempenho e geração de gráficos.
- *Scikit-Learn* - utilizada para pré-processamento de dados, avaliação de modelos e obtenção de métricas de desempenho.

No desenvolvimento do aplicativo móvel, as principais etapas incluíram a implementação do *backend* com *Flask*, para criar a lógica e funcionalidades do servidor, a containerização com *Docker*, para facilitar a implantação e gerenciamento em diferentes ambientes, o desenvolvimento da interface do aplicativo utilizando *Expo*, para criar uma experiência interativa e responsiva e, finalmente, a integração de todas as partes do aplicativo e modelo, para garantir o funcionamento harmonioso e eficiente do sistema como um todo.

O Aplicativo móvel foi desenvolvido utilizando a Linguagem *Python*, para o *Backend* e *React Native*, para o *Frontend*. Para tanto, fez-se uso das seguintes bibliotecas:

- *Flask* - *Framework* utilizado para desenvolver o *backend* da aplicação móvel de reconhecimento facial;
- *PostgreSQL* - um sistema de gerenciamento de banco de dados relacional robusto, de código aberto, com suporte completo a SQL; e
- *Expo* - *Framework* utilizado para desenvolver a interface do usuário.

4.1 Base de Dados

A base de dados utilizada foi a *KomNET*, cuja obtenção foi resultado de uma busca meticulosa por fontes de dados adequadas para o projeto, com o critério específico de selecionar imagens capturadas por dispositivos móveis.

A base de dados foi identificada e acessada por meio do repositório disponível em [8]. Este conjunto de dados contém mais de 39.600 imagens de rostos originados de três fontes diferentes: câmera de celular, câmera digital e mídias sociais (Facebook). Devido à natureza específica do tema abordado,

foram utilizadas exclusivamente as imagens vindas de câmeras de dispositivos móveis.

Ressalta-se, que as imagens foram coletadas sem imposição de condições específicas, como iluminação controlada, fundo padronizado, restrições quanto a cortes de cabelo, presença de barba, uso de qualquer tipo cobertura na cabeça ou rosto, além de possuir expressões faciais variadas. Essa abordagem permitiu trabalhar com cenários mais parecidos com os do mundo real.

Na Figura 3, são ilustradas algumas das características presentes nas imagens coletadas.

Figura 3: Variedade de rostos capturados por câmeras de celular.



Fonte: KomNET Dataset.

4.2 Pré-processamento

O pré-processamento das imagens é essencial para a eficácia dos sistemas de reconhecimento facial, especialmente ao lidar com conjuntos de dados diversificados, como é o caso da base de dados da *KomNET*. A seguir, serão descritos os procedimentos aplicados, incluindo técnicas de aumento de dados (*data augmentation*) utilizadas para enriquecer o conjunto de dados.

4.2.1 Dimensionamento e Normalização

Inicialmente, todas as imagens foram redimensionadas para uma resolução padrão de 224x224 pixels, facilitando o processamento e permitindo o uso mais eficiente em modelos de redes neurais convolucionais.

Além disso, as intensidades dos pixels foram normalizadas para o intervalo [0, 1], a partir da divisão de cada valor de pixel pelo valor máximo (255). Essa normalização é essencial para garantir a estabilidade do treinamento do modelo, evitando problemas de escala nos dados.

4.2.2 Aumento de Dados

Apesar de o banco de dados já utilizar uma estratégia para aumento de dados, optou-se por expandir seu uso ainda mais, manualmente, proporcionando, assim, maior controle sobre o processo e garantindo que as imagens geradas seriam relevantes para o contexto específico do reconhecimento facial. Na estratégia, foram aplicadas as transformações a seguir.

- Rotação: as imagens foram rotacionadas em ângulos aleatórios para simular diferentes orientações faciais, aumentando a variabilidade dos dados e permitindo a possibilidade de reconhecer rostos em diversas perspectivas.
- Translação: foi realizado um deslocamento aleatório das imagens horizontalmente e verticalmente para introduzir variações de posição.

- Espelhamento Horizontal: algumas imagens foram espelhadas horizontalmente para diversificar a orientação dos rostos, permitindo que o modelo aprendesse com diferentes perspectivas.
- Alteração de Brilho e Contraste: foram realizados ajustes aleatórios de brilho e contraste nas imagens para simular condições variadas de iluminação.
- Zoom e Corte: aplicou-se zoom aleatório e recorte nas imagens para destacar diferentes partes do rosto. Isso ajuda o modelo a aprender a reconhecer características específicas dos rostos, independentemente de sua localização na imagem.
- Ajuste de Inclinação (*Shear*): foi introduzida uma inclinação aleatória nas imagens para criar perspectivas variadas. Isso é importante para aumentar a capacidade do modelo de generalizar para diferentes orientações faciais.

Essas técnicas foram aplicadas preservando-se as características essenciais das faces e garantindo a diversidade no conjunto de dados, tornando o modelo mais robusto e capaz de generalizar para novas condições de captura de imagem.

4.2.3 Divisão em Conjuntos de Treinamento e Validação

Após o pré-processamento e o aumento de dados, as imagens foram divididas em conjuntos de treinamento (80%) e validação (20%). Essa divisão equilibrada garante uma avaliação justa do modelo em dados não vistos durante o treinamento, promovendo melhor capacidade de generalização.

A estratégia de 80% para treinamento e 20% para validação é amplamente adotada porque permite maximizar o tamanho do conjunto de treinamento, essencial para o aprendizado eficaz do modelo, enquanto reserva dados suficientes para avaliar seu desempenho de forma confiável em novos exemplos.

4.3 Modelo para Reconhecimento Facial

Para a tarefa de construção do modelo, empregou-se uma abordagem de transferência de conhecimento, utilizando a arquitetura *MobileNet* como base.

O *MobileNet* é uma rede neural convolucional leve e eficiente, projetada inicialmente para aplicações móveis e tarefas de visão computacional em dispositivos com recursos limitados. Além disso, possui capacidade efetiva de processar e reconhecer faces em imagens de baixa resolução. Essa capacidade é essencial, especialmente considerando a natureza das imagens provenientes de câmeras de celulares, que podem apresentar resoluções variadas e nem sempre ideais para análise detalhada [9].

4.3.1 Adaptação do Modelo

Para adaptar a *MobileNet* ao problema de reconhecimento facial com a base de dados *KomNET*, foram realizadas as modificações descritas a seguir.

- Camadas Personalizadas: foram incluídas camadas adicionais no topo da *MobileNet* para personalizar a rede neural de acordo com as características específicas do conjunto de dados. Essas camadas adicionais foram projetadas para ajustar a saída da *MobileNet* aos requisitos do problema de verificação facial, permitindo melhor adaptação aos dados de entrada.
- Camadas Convolucionais: aplicou-se a técnica de ajuste fino em algumas das camadas convolucionais da *MobileNet*. Isso permite que as camadas convolucionais

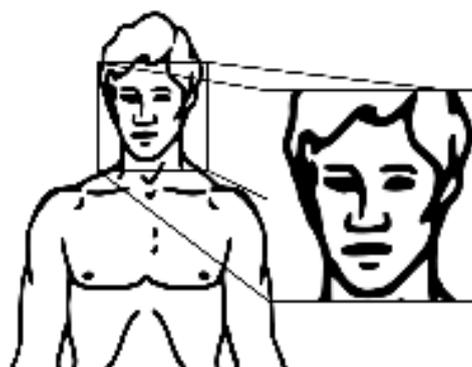
aprendam características específicas das faces presentes na base de dados, melhorando a capacidade de generalização do modelo para reconhecimento facial.

4.3.2 Inserções de Novos Indivíduos

A adição contínua de novos indivíduos ao sistema é essencial, considerando a natureza do aplicativo e seu uso futuro. Para viabilizar isso, faz-se necessário implementar um método de atualização do modelo.

Dessa forma, é possível cadastrar um novo usuário por meio do seguinte processo: durante o cadastro, o sistema captura múltiplas imagens da pessoa utilizando a câmera frontal do dispositivo. Cada imagem capturada é então submetida ao classificador em cascata de Haar para identificar a presença de faces, como ilustrado na Figura 4.

Figura 4: Ilustração do Modelo haar cascade adaptado.



Fonte: Autoria própria.

Durante a implementação, foram feitos ajustes no tamanho da seleção e no espaçamento entre as identificações, o que contribuiu para melhorar a precisão e a eficiência do processo de detecção facial. Esses ajustes permitem que o algoritmo identifique faces em diferentes escalas e posições na imagem, tornando-o mais robusto e capaz de lidar com variações nas condições de captura de imagem.

Se uma face for detectada, suas coordenadas na imagem são armazenadas no banco de dados, juntamente com informações de identificação associadas à pessoa cadastrada.

Após a fase inicial de cadastro, o modelo de reconhecimento facial passa por ajuste fino, utilizando as novas amostras de faces cadastradas. Essa atualização ocorre de maneira periódica devido ao tempo necessário para o treinamento e ao aprimoramento contínuo da precisão do sistema.

4.4 Desenvolvimento do Aplicativo Mobile

Nesta seção, são detalhadas as etapas e tecnologias utilizadas no desenvolvimento do aplicativo móvel, abrangendo tanto o desenvolvimento do *backend* quanto do *frontend*, proporcionando uma visão detalhada da arquitetura e das principais funcionalidades implementadas.

4.4.1 Backend

Nesta etapa, foi desenvolvido um sistema básico de gerenciamento, utilizando o *framework Flask* em *Python* e um banco de dados em *PostgreSQL*. O sistema incorpora operações CRUD (*Create, Read, Update, Delete*) para entidades do contexto escolar, como Professor, Turma, Aluno e Presença. É importante destacar que o uso desse contexto escolar foi apenas uma escolha para orientação e facilitação do desenvolvimento, mas o sistema

pode ser aplicado a diferentes contextos e finalidades. Também foram desenvolvidas as conexões com o modelo de reconhecimento, permitindo ações de cadastro e autenticação.

Para assegurar a escalabilidade e facilitar a implantação, o sistema foi containerizado com o *Docker* e implantado em um servidor *NGINX*. Essa abordagem permitiu criar um ambiente de desenvolvimento e produção mais controlado e simplificado, facilitando a distribuição e a execução do sistema em diferentes ambientes de hospedagem.

4.4.2 Frontend

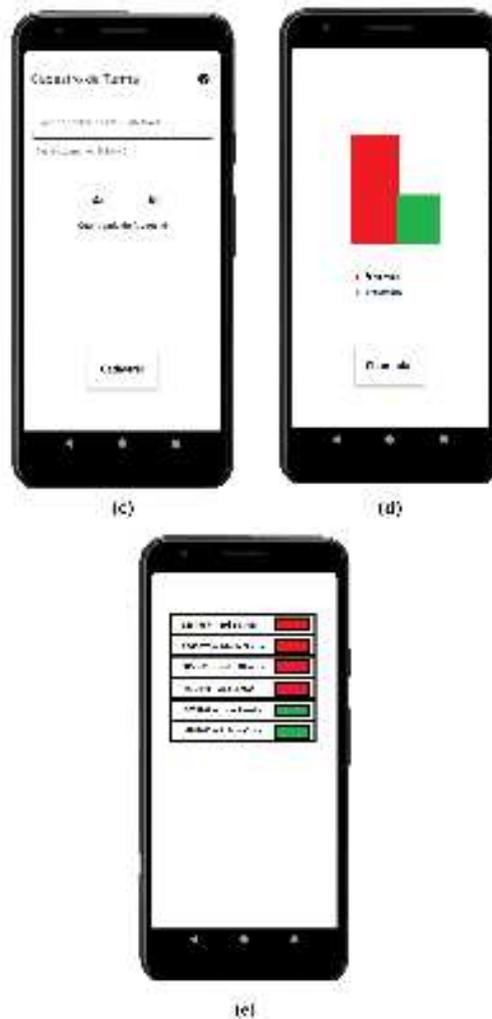
O *frontend* foi construído utilizando o *framework Expo*, aproveitando técnicas modernas para oferecer uma experiência segura e eficaz aos usuários. O design adotado foi planejado para ser simplista e intuitivo, visando garantir ao usuário uma experiência agradável e acessível em dispositivos *android* e *ios*.

Ao iniciar o aplicativo, os usuários podem explorar as seções a seguir.

- Autenticação com Conta *Google* (Figura 5(a)): o aplicativo oferece uma funcionalidade de autenticação com contas do *Google*, sem a necessidade de cadastro adicional.
- Turmas Cadastradas e Criação de Turmas (Figura 5(b) e Figura 5(c), respectivamente): os usuários têm acesso a uma lista das turmas cadastradas e podem criar novas turmas diretamente pelo aplicativo. Isso permite um gerenciamento flexível das turmas.
- Situação de Presença em Tempo Real (Figura 5(d)): uma funcionalidade destacada é o gráfico em tempo real que exhibe a situação de presença da turma, fornecendo aos professores informações visuais claras sobre a participação dos alunos.
- Lista de Indivíduos Cadastrados para Autenticação (Figura 5(e)): esta seção exhibe uma lista dos alunos ou usuários registrados no sistema. Ao clicar no nome de um indivíduo nesta lista, o usuário é direcionado para a abertura da câmera frontal do dispositivo. Neste momento, o sistema realizará uma verificação facial para registrar a presença da pessoa automaticamente.

O *frontend* desenvolvido oferece uma solução prática e moderna para a gestão escolar, destacando-se pela sua usabilidade e pelo foco na experiência do usuário.

Figura 5: Disposição de telas do aplicativo.



Fonte: Autoria própria.

5. RESULTADOS

A análise de desempenho do sistema de autenticação facial foi realizada a partir da base de dados *KomNET*, composta por 50 classes, cada uma representando um indivíduo da base de dados, composta, em sua maioria, por 24 imagens da face de um indivíduo. Na fase de treinamento, foi utilizado um conjunto de dados composto por 1.012 imagens distribuídas nas 50 classes distintas. Essas imagens foram submetidas a um processo de *data augmentation*, utilizando o *ImageDataGenerator*, uma biblioteca do pacote *tensorflow.keras.preprocessing.image*, utilizando as técnicas citadas na Seção 4.2.2. É importante notar, que as imagens resultantes dessas transformações não foram salvas fisicamente, pois o gerador realiza as alterações em tempo real durante o treinamento.

Posteriormente, para avaliar o desempenho do modelo treinado, utilizou-se um conjunto separado de 205 imagens, também distribuídas nas mesmas 50 classes do conjunto de treinamento. Essas imagens foram reservadas exclusivamente para testar a capacidade do modelo de generalizar o aprendizado adquirido durante o treinamento.

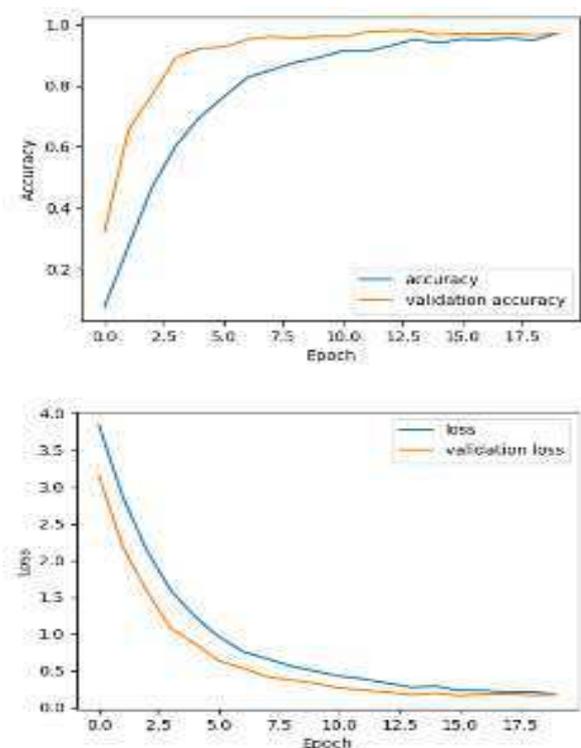
As métricas utilizadas para avaliar o desempenho são descritas a seguir [10].

- *Precision*: mede a proporção de exemplos classificados como positivos que são verdadeiramente positivos.

- *Recall*: mede a proporção de exemplos verdadeiros positivos que foram corretamente identificados pelo modelo.
- *F1-score*: é uma medida que combina a precisão e o *recall* em uma única métrica, calculada como a média harmônica dessas duas métricas.
- *Support*: representa o número de ocorrências de cada classe no conjunto de dados de validação. Esta medida indica a quantidade de exemplos de cada classe que foram usados na avaliação do modelo.

Ao final, o modelo apresentou resultados promissores, com uma precisão de, aproximadamente, 97,13 % na fase de treinamento e 97,07 % na fase de validação (Figura 6).

Figura 6: Gráfico de Precisão e Gráfico de Perda.



Fonte: Autoria própria.

Os gráficos demonstram o progresso do modelo durante o treinamento, exibindo o aumento da precisão e a diminuição da perda ao longo das épocas.

Na Tabela 1, destaca-se a precisão global do modelo, bem como métricas detalhadas por classe, incluindo precisão, recall e F1-score.

Tabela 1: Métricas de Avaliação do Modelo.

	Precision	Recall	F1-score	Support
Média Macro	0,97	0,97	0,96	205
Média Ponderada	0,97	0,97	0,97	205

Fonte: Autoria própria

Os resultados próximos de 1,0, tanto para a média macro quanto para a média ponderada, indicam um bom desempenho geral do modelo na tarefa de autenticação para todas as classes. Isso sugere que o modelo está generalizando bem para novos exemplos, com alta precisão e métricas robustas de avaliação. O valor elevado das métricas em relação à média ponderada e média macro reforça o balanceamento das classes, o que é excelente para o treinamento de modelos de aprendizado de máquina. Esses resultados são encorajadores e indicam que o modelo está realizando bem sua tarefa de classificação.

Vale ressaltar, que a etapa de treinamento foi realizada de forma *offline*. Para a etapa de autenticação, cada imagem era enviada para uma máquina remota, na qual estava sendo realizado o processo de classificação, de forma a simular um processo real a partir de um *smartphone*. Nesse cenário, o acesso externo realizado pelo *apk* gerado com o *Expo*, levava a um processo frequente de *upload* de imagens para a máquina na qual o *backend* se encontrava em execução. Essa etapa impactou no desempenho do sistema, em virtude do desempenho da máquina virtual utilizada e das oscilações na conexão com a internet.

6. CONSIDERAÇÕES FINAIS E SUGESTÕES PARA TRABALHOS FUTUROS

Nesta seção, serão apresentadas as considerações finais sobre o trabalho desenvolvido¹, suas principais contribuições, suas limitações, possíveis pontos de aprimoramentos para o futuro e também lições aprendidas.

6.1 Contribuições e Limitações

Como principais contribuições do trabalho, pode-se destacar a seleção de uma arquitetura adequada para sanar limitações citadas anteriormente em dispositivos *smartphones*, além da produção de um artefato funcional que satisfaz o processo de gerenciamento de presença em um ambiente, conforme métricas de desempenho apresentadas.

Para o uso em um cenário real, as principais limitações deste trabalho estão relacionadas a dois fatores: primeiramente, a importância de contar com uma máquina virtual (*Virtual Machine*) com IP flutuante público, que possua uma boa conexão à internet, considerando que o acesso externo realizado pelo *apk* gerado com o *Expo*, levava a um processo frequente de *upload* de imagens para a máquina na qual o *backend* se encontrava em execução (uma máquina virtual disponibilizada pela UFCG), o que impactou nos resultados, devido a limitações de desempenho e conectividade.

Outra limitação estava relacionada ao fato de não terem sido utilizadas imagens capturadas diretamente da câmera do celular no qual rodava o aplicativo. Tal fato ocorreu devido à falta de controle causado pela inexperiência na configuração e utilização da câmera do celular, por meio do *React Native*. Esta limitação afetou diretamente o desenvolvimento e a implementação do sistema de reconhecimento facial, pois a capacidade de captura de imagens diretamente do dispositivo móvel teria sido importante para avaliar o desempenho do sistema com imagens capturadas durante o seu uso.

¹

6.2 Sugestões para Trabalhos Futuros

No futuro, há diversas possibilidades para melhorar o aplicativo móvel visando uma aplicação real, a saber: controle estável da câmera e eficiência no *upload* de imagens. Uma abordagem promissora seria adicionar guias na tela para orientar os usuários durante o processo de captura de imagens, além de implementar um *upload* baseado em *frames*, o que requer um serviço na nuvem mais estável para processamento e armazenamento eficientes das imagens.

Investir em recursos para adquirir uma infraestrutura mais robusta na nuvem pode ser benéfico para suportar essas funcionalidades adicionais. Isso permitiria a expansão do uso do sistema em laboratórios acadêmicos, salas de aula e outros ambientes educacionais na UFCG.

Além disso, seria valioso investir na aplicação do sistema em um estudo de campo controlado para avaliar a adesão dos participantes, bem como coletar *feedback* sobre sua usabilidade e eficácia. Essas medidas ajudariam a refinar e otimizar o sistema, garantindo melhor experiência para os usuários e uma implementação mais eficaz em contextos educacionais e institucionais.

6.3 Lições Aprendidas

Ao refletir sobre este projeto, algumas lições importantes surgiram. Primeiramente, aprendi a valorizar o planejamento adequado antes de iniciar qualquer projeto de desenvolvimento, especialmente ao lidar com tecnologias complexas como o reconhecimento facial em aplicativos móveis. Isso inclui não apenas definir claramente os objetivos e requisitos do projeto, mas também identificar as ferramentas e tecnologias mais adequadas para alcançar esses objetivos.

Durante o desenvolvimento, enfrentei alguns desafios técnicos devido à minha falta de experiência em desenvolvimento *mobile*. No entanto, com o esforço adequado e a disposição para aprender, consegui superar esses desafios e adquirir conhecimentos valiosos nesse campo específico de desenvolvimento.

Uma das lições mais significativas foi a importância de escolher as ferramentas certas desde o início. Depois de enfrentar resultados insatisfatórios ao tentar construir todo o modelo de reconhecimento facial, adotei a abordagem de transferência de aprendizado, utilizando o modelo *MobileNet* pré-treinado como base. Essa decisão foi crucial para obter melhores resultados, aproveitando o conhecimento prévio do modelo e adaptando-o para atender às necessidades específicas do projeto.

Além disso, aprendi a importância de buscar orientação e *feedback* de especialistas durante o processo de desenvolvimento. Receber orientação da minha orientadora foi incrivelmente valioso e mostrou como a colaboração de mentores pode ajudar a superar desafios técnicos e garantir uma abordagem mais eficaz para resolver problemas complexos.

Em resumo, este projeto me ensinou a importância do planejamento, da escolha cuidadosa de ferramentas e da adaptação de estratégias com base nos resultados obtidos. A transição para o uso de um modelo de transferência de aprendizado, aliada à orientação recebida, foi fundamental para o sucesso do projeto e destacou como aprender com desafios pode levar a resultados mais satisfatórios em projetos de desenvolvimento de tecnologia.

7. AGRADECIMENTOS

Gostaria de expressar minha mais profunda gratidão a todas as pessoas que contribuíram para a realização deste trabalho. Em especial, dedico meus sinceros agradecimentos à minha orientadora, Professora Joseana Macêdo Fehine Regis de Araújo, pela orientação exemplar, apoio incansável e valiosas contribuições ao longo deste processo. Sua dedicação e expertise

foram fundamentais para o desenvolvimento deste trabalho. Também desejo estender meus agradecimentos aos demais professores do curso por sua orientação e dedicação ao longo dessa jornada.

À minha família, aos amigos e à minha querida namorada, meu profundo agradecimento pelo amor, apoio incondicional e compreensão durante toda essa jornada acadêmica. Suas palavras de encorajamento e presença constante foram essenciais para minha motivação e sucesso. Por fim, gostaria de mencionar uma homenagem ao Zabuza Momochi, que me inspirou com sua coragem e determinação em face das adversidades.

Cada um de vocês teve um papel fundamental no meu crescimento pessoal e acadêmico. Sou imensamente grato por todo apoio e incentivo ao longo dessa jornada.

REFERÊNCIAS

- [1] BAKSHI, Urvashi; SINGHAL, Rohit. A SURVEY ON FACE DETECTION METHODS AND FEATURE EXTRACTION TECHNIQUES OF FACE RECOGNITION. *International Journal of Emerging Trends & Technology in Computer Science (IJETTCS)*, [S. l.], p. 233-237, maio-junho 2014. Disponível em: <https://pdfs.semanticscholar.org/4f9a/dc4d6aa78b1a882a517a927bb45e5f38e407.pdf>. Acesso em: 05 mai. 2024.
- [2] ZHAO, W. et al. Face recognition: A literature survey. *Acm Computing Surveys (CSUR)*, ACM, v. 35, n. 4, p. 399-458, dezembro de 2003. Disponível em: https://inc.ucsd.edu/mplab/users/marni/Igert/Zhao_2003.pdf. Acesso em: 10 out. 2023.
- [3] CHOI, K. et al. Realtime training on mobile devices for face recognition applications, *Pattern recognition*, v. 44, n. 2, p. 386-400, 2011. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S003132031000395X>. Acesso em 10 abr. 2024.
- [4] SUNARYONO, D., SISWANTORO, J., & ANGGORO, R. (2019). An Android Based Course Attendance System Using Face Recognition. *Journal of King Saud University - Computer and Information Sciences*. doi:10.1016/j.jksuci.2019.01.006
- [5] TEJ CHINIMILLI, B., T, A., KOTTURI, A., REDDY KAIPU, V., & VARMA MANDAPATI, J. (2020). Face Recognition based Attendance System using Haar Cascade and Local Binary Pattern Histogram Algorithm. 2020 4th International Conference on Trends in Electronics and Informatics (ICOEI)(48184). doi:10.1109/icoei48184.2020.9143046
- [6] KHAN, S., AKRAM, A. & USMAN, N. Real Time Automatic Attendance System for Face Recognition Using Face API and OpenCV. *Wireless Pers Commun* 113, 469-480 (2020). <https://doi.org/10.1007/s11277-020-07224-2>
- [7] MORAES, J. Controle de Acesso Baseado em Biometria Facial. Dissertação (Mestrado) Universidade Federal do Espírito Santo, 2010. Disponível em: <https://core.ac.uk/download/pdf/161367392.pdf>. Acesso em: 16 abr. 2024.
- [8] I. N. G. A. Astawa, I. K. G. D. Putra, M. Sudarma, and R. S. Hartati, "Komnet: Face image dataset from various media for face recognition," *Data in Brief*, p. 105677, 2020. Disponível em:

<https://www.sciencedirect.com/science/article/pii/S2352340920305710>. Acesso em 16 abr. 2024.

[9] HOWARD, G. ANDREW, et al. (2017) Mobilenets: efficient convolutional neural networks for mobile vision applications. ArXiv:1704.04861. Disponível em: https://www.researchgate.net/publication/316184205_MobileNets_Efficient_Convolutional_Neural_Networks_for_Mobile_Vision_Applications. Acesso em 07 mai. 2024.

[10] FLACH PA, KULL M. Precision-Recall-Gain curves: PR analysis done right. In: Proceedings of the 28th International Conference on Neural Information Processing Systems (NIPS 2015). Cambridge: MIT Press: 2015. p. 838–46. Disponível em: <https://bmcgenomics.biomedcentral.com/articles/10.1186/s12864-019-6413-7>. Acesso em 08 mai. 2024.