

Control and Security System for Classroom Access Based on Facial Recognition

Cedric Monteiro¹, Eduardo Ogasawara¹, Laercio Gonçalves¹, João R. de Toledo Quadros¹

¹ Escola de Informática e Computação

Centro Federal de Educação Tecnológica Celso Suckow da Fonseca – CEFET/RJ, Rio de Janeiro, Brasil
{cedricmonteirobr, laerciobrito74, jquadros80}@gmail.com, eogasawara@ieee.org

Abstract – This work presents a facial recognition system based on spectral analysis. With this system, it is possible to provide greater security of access to a classroom, avoiding irregularities, such as falsified signatures on the presence sheet, or use of adulterated identities. It applies an image recognition process in which it seeks to extract relevant information from an image, then encode and compare it with other facial data stored in an image database. This information of the images represents a set of characteristics that present the variations between the images of the faces collected by the system and those contained in the image database. The Facial Recognition System is composed of two processing modules: training and recognition. It was applied in a high school classroom to evaluate the usefulness and accuracy of these algorithms for people recognition.

Keywords - Facial Recognition; System Information; Safety; Images; Database.

I. INTRODUÇÃO

Considerando-se as questões atuais relativas à segurança e controle automatizado de acesso a locais específicos, tais como escolas e prédios públicos e a presença invasiva de câmeras de monitoramento, há de se dar importância às questões que envolvem identificação e mapeamento de informações contidas em imagens produzidas por tais dispositivos. Para isso tornam-se necessário o desenvolvimento de ferramentas e sistemas que procurem trabalhar de forma autônoma com processamento digital desse tipo de dados para atender o objetivo de reconhecimento de padrões a partir de uma base de dados específica para esse fim [1].

Tais tipos de sistemas são configurados como modelos de reconhecimento de padrões, que possuem grau de complexidade tal que exigem o trabalho com dois padrões de abordagens: um que trata da extração e partição das características desses dados e outro que trata da classificação com algoritmos heurísticos, baseados em estatísticas e técnicas de inteligência computacional [2] [3].

Para sistemas de processamento e identificação de imagens de pessoas, o uso de modelos de reconhecimento facial requer menos interação direta na identificação dessas pessoas que a maioria dos métodos biométricos existentes. Isso acontece uma vez que se pode utilizar quaisquer fotos ou imagens, sem que haja uma interação direta da pessoa investigada com o sistema em si. Isso é considerado uma vantagem na utilização

desse tipo de sistema, pois, devido a essa característica, é possível utilizar captação de rostos em uma multidão, e identificá-los, sem a pessoa nem ao menos perceber essa ação [4].

Em ambiente escolares, por exemplo, o controle da presença permite que se garanta que apenas alunos inscritos na disciplina possam frequentá-la, evitando-se problemas tanto de ordem jurídica, quanto disciplinar. A automação desse processo de verificação facilita em muito o trabalho da escola. Processos automatizados, que tenham um grau de certeza confiável, são necessários nas condições atuais, nas quais segurança e controle baseado em graus de certeza mais acurados são imprescindíveis [5].

O presente trabalho se propõe a mostrar um sistema automatizado de controle de presença de alunos em sala de aula, a partir do reconhecimento da face de cada inscrito na turma, sendo que cada pessoa inscrita tem seu rosto padrão inserido em um banco de imagens. Esse processo de reconhecimento de faces se dá por meio da busca e extração informações relevantes de uma imagem, para em seguida codificá-las e compará-las com outras imagens de faces armazenadas nesse banco de imagens.

O propósito principal do desenvolvimento desse sistema é prover um meio para aumentar a segurança e controle de acesso às salas de aulas, de modo a prevenir irregularidades, tais como anotações incorretas da presença de alunos, ou impedir o acesso de pessoas não autorizadas, identificando-as de forma rápida e precisa [6].

Esse sistema é foi construído com componentes matemáticos baseados na teoria espectral, que se utiliza de parâmetros de autovalores e autovetores [7] [8] obtidos a partir da matriz de covariância do conjunto de imagens de faces [9] [10]. Esses autovetores, por serem um conjunto de características que representam as variações entre as imagens das faces contidas no banco de imagens, são também denominados de "autofaces" [7].

Ele foi aplicado em uma turma de ensino médio e técnico de uma escola pública federal de ensino. A turma possuía dez alunos, sendo que seis se voluntariam a compor a base de dados inicial. Foram tiradas várias fotos de um conjunto de alunos para compor a base de treinamento. Posteriormente, outras novas fotos foram tiradas dos mesmos alunos para

verificar se o sistema iria reconhecê-los a partir dos resultados armazenados na base de treinamento.

Também foram testadas outras duas fotos fora do espaço de "autofaces", com o propósito de testar a precisão do software em apontar faces fora do espaço definido na fase de treinamento do sistema e, com isso, também comprovar a questão de segurança relativa ao sistema.

Esse trabalho está dividido em uma introdução, um estudo de trabalhos relacionados, a descrição do desenvolvimento do sistema, a descrição da aplicação do sistema dentro do ambiente escolar, a apresentação dos resultados observados e as conclusões obtidas.

II. TRABALHOS RELACIONADOS

O Processamento Digital de Imagens visa a manipulação de imagens por algoritmos computacionais, com o objetivo de tratar imagens dentro de métodos matemáticos próprios, podendo ser utilizados para melhorar características das imagens ou auxiliar na identificação de características delas dentro de padrões previamente armazenados. Nesse tipo de processo, tanto as entradas como as saídas são imagens, sendo que a saída é uma imagem adequada aos processos algorítmicos ou funções matemáticas aplicadas pelo sistema [10].

Em Gonzalez e Woods [11] as técnicas de análise de processamento digital de imagem são apresentadas contendo três funções principais: o processamento de baixo nível, com funções que tratam eventos de forma automática, sem que haja tratamentos específicos contendo inteligência; processamento de nível intermediário, que tratam da extração e caracterização de componentes em uma imagem e processamento de alto nível, que envolve os processos de reconhecimento e interpretação, aplicando-se de vários tipos de algoritmos com componentes de inteligência computacional.

Para Augusto [12], os componentes de um sistema completo de processamento são: aquisição dos dados (no caso, imagens), pré-processamento, segmentação, representação e descrição, reconhecimento, interpretação e base de imagens padrão.

Em relação a identificação, detecção e tratamento de imagens faciais, existem estudos que mostram esse tipo de tratamento associado com diversos outros modelos matemáticos, tais como: os que tratam das informações de imagens no nível de escala de cinza [13]; os que identificam as arestas das imagens [14]; os que trabalham por detecção de cor [15]; ou aqueles que identificam a geometria associada às imagens [16].

Em relação a reconhecimento facial, há métodos que fazem uso de análise estatística, ou conjuntos de medidas de características (como manipulação de n -*tupla* ou vetores) [17]. Esses métodos usam extração de vetores característicos das imagens, associados a métodos estatísticos, com o fim de separar e classificar as imagens identificadas [17].

Existem outros métodos de reconhecimento facial que fazem uso de classificadores bayesianos e arranjos probabilísticos junto com regras de decisão para a análise de estrutura, na qual padrões têm representações em uma forma

simbólica (tais como strings, listas e árvores) [18]. Existem ainda os métodos de reconhecimento baseados na associação entre os símbolos gerados da imagem par a par, com uso de modelos que transformam as características de pontos da imagem em padrões simbólicos de uma linguagem artificial (como se fossem mnemônicos ou sentenças) [19].

Outros métodos de reconhecimento facial seguem algoritmos heurísticos ou neurais, no qual o reconhecimento é realizado utilizando-se Redes Neurais Artificiais [12] [1].

Com relação a outras aplicações, existem trabalhos de reconhecimento de imagens para auxiliar na locomoção de veículos autônomos simples [20], para auxiliar no reconhecimento de emoções a partir da interpretação de imagens faciais [21] entre outros tipos de aplicação.

Esse trabalho aborda métodos de reconhecimento facial, baseados em mapeamento, treinamento e reconhecimento com uso de matrizes representativas da imagem em escala de cinza e comparações com análises estatísticas, com o uso de equações desenvolvidas no trabalho de Turk e Pentland [22].

Apesar de ser um método antigo, a escolha do método de Turk e Pentland [22] se deve por ter sido visto em trabalhos posteriores [23] [24] que outras técnicas utilizadas para situações similares podem resultar em uma perda de até 20% na precisão de identificação [25] em casos similares, ou seja, para casos como o apresentado nesse trabalho, podem ocorrer que em cada dez exames de identificação facial, há falhas em até dois desses exames. O uso das equações de Turk e Pentland em outros trabalhos [26] indicaram uma precisão de 90% a 95% para situações ao estudo de caso em questão.

Em trabalhos utilizando essa técnica [27] também foi possível confirmar que casos de imprecisão, em termos de identificação sobre as imagens de alunos que compuseram uma base de imagens, tendem a ocorrer quando há aspectos específicos de alteração de características das imagens.

III. SISTEMA DE RECONHECIMENTO FACIAL

O Sistema de Reconhecimento Facial desenvolvido se constitui de dois módulos básicos: o de treinamento e o de reconhecimento.

No módulo de fase de treinamento é criado um banco de dados de imagens de faces, chamado de conjunto ou base de treinamento do sistema. Para isso, são coletados um conjunto de imagens de faces das pessoas, conjunto esse constituído de uma certa quantidade de fotos diferentes por cada pessoa, sendo importante que haja variações na expressão e inclinação do rosto. Com esse conjunto de imagens faciais obtidas, são calculadas as "autofaces" de todas as imagens de faces, mantendo apenas um número M de imagens correspondentes aos maiores valores dos autovetores. Essas M imagens vão definir o "espaço das faces" que será utilizado para a identificação.

Cada conjunto de fotos da base de dados vai constituir uma classe k específica. Sobre cada classe k é feito a um cálculo para gerar a média Ψ de todas as faces.

No módulo de reconhecimento, uma nova imagem é apresentada ao sistema, sendo verificado a distância entre essa imagem e o "espaço das faces", utilizando-se de algoritmos

para cálculos de distâncias de imagens identificados no trabalho de Cha [28]. Se essa distância for suficientemente pequena, essa nova foto é considerada como uma imagem de um rosto, e é classificada como sendo uma face conhecida ou desconhecida. Caso contrário, a foto cujo valor ultrapasse o limite é classificada como um outro tipo de imagem fora do espaço de identificação.

Quando ocorre o evento da foto ser uma imagem de rosto desconhecida do sistema, tem-se a opção de voltar à fase de treinamento e treinar o sistema com essa nova imagem, calculando novamente as "autofaces". Dessa forma é possível incorporar novas imagens de faces ao sistema.

O sistema foi concebido para, em trabalhos futuros, ser adaptado com mais facilidade a detecção de faces em imagens compostas (como uma imagem de um grupo de pessoas), para ser possível utilizar os rostos das pessoas dessa foto e criar a base de dados do módulo de fase de treinamento.

A. Fase de treinamento

Na fase de treinamento obtém-se as Γ imagens ($\Gamma_1, \Gamma_2, \Gamma_3, \dots, \Gamma_M$) que se transformam em um número de M matrizes, que vão compor o conjunto de treinamento. Uma vez obtidas essas matrizes associadas as imagens, utiliza-se da Equação 1 para obter uma média dos valores dessas imagens:

$$\Psi = \frac{1}{M} \sum_{n=1}^M \Gamma_n = \frac{1}{M} (\Gamma_1 + \Gamma_2 + \dots + \Gamma_n) \quad (1)$$

Com essa média Ψ , calcula-se a diferença entre cada imagem e a média. Desse modo, obtém-se as matrizes $\Phi_1 = \Gamma_1 - \Psi$, $\Phi_2 = \Gamma_2 - \Psi$, ..., $\Phi_M = \Gamma_M - \Psi$. Assim, transforma-se cada uma das M matrizes originais Γ em novas matrizes Φ . Cada matriz Φ é de tamanho $N \times N$ (sendo N o número de pixels). A partir dela é constituída um vetor que tenha N^2 posições. Feito isso, encontra-se uma matriz A de tamanho $N^2 \times M$ (número de pixels por número de imagens), com a transposta A^T de tamanho $M \times N^2$, conforme a Figura 1.

$$A = \begin{bmatrix} \Phi_{11} & \dots & \Phi_{M1} \\ \Phi_{12} & \dots & \Phi_{M2} \\ \vdots & \ddots & \vdots \\ \Phi_{1N^2} & \dots & \Phi_{MN^2} \end{bmatrix} \quad A^T = \begin{bmatrix} \Phi_{11} & \Phi_{12} & \dots & \Phi_{1N^2} \\ \Phi_{21} & \Phi_{22} & \dots & \Phi_{2N^2} \\ \vdots & \vdots & \ddots & \vdots \\ \Phi_{M1} & \Phi_{M2} & \dots & \Phi_{MN^2} \end{bmatrix}$$

Figura 1 – Exemplo de matriz A e matriz A^T .

O próximo passo é encontrar a matriz de covariância $C = A.A^T$. Nesse ponto, nota-se o problema da dimensão final de C , que fica em $N^2 \times N^2$, o que torna essa matriz de difícil trato computacional. A solução é reduzir o número de imagens analisadas, uma vez que a dimensão do espaço é da ordem M , que é bem menor que o espaço definido por N^2 . Assim, há somente $M-1$, ao invés de N^2 , autovetores significativos. Dessa forma, calcula-se uma matriz de covariância $L = A^T.A$, de dimensão $M \times M$, ao invés de uma matriz $N^2 \times N^2$.

Dessa feita, os cálculos de autovalores e autovetores são realizados em cima da matriz de L ao invés de se calculá-los sobre a matriz C . Os autovetores de L assumem os valores calculados, de modo que as Equações matriciais 2, 3, 4, 5 e 6 assumem:

$$L.v_i = \mu_i.v_i \quad (2)$$

$$A^T.A.v_i = \mu_i.v_i \quad (3)$$

$$(A^T.A.v_i - \mu_i.I.v_i) = 0 \quad (4)$$

$$(A^T.A - \mu_i.I) v_i = 0 \quad (5)$$

$$\det((A^T.A - \mu_i.I) = 0 \quad (6)$$

Sendo que μ_i são os autovalores (valores escalares), v_i são os autovetores e I é a matriz identidade. A multiplicação de μ_i com a matriz identidade forma uma nova matriz com os autovalores a ser comparada com a relação matricial $A^T.A$.

Ao final, encontra-se os M autovalores e os M autovetores. Com esses M autovetores da matriz L pode-se calcular as M "autofaces" u_i . Com isso, o cálculo computacional é reduzido da ordem de N^2 (baseado no número total de pixels da imagem) para ordem M (número de imagens do conjunto de treinamento).

B. Fase de Reconhecimento

Na fase de reconhecimento, uma nova imagem de cada face Γ_i é projetada no espaço das "autofaces" (ω) a partir da Equação 7:

$$\omega_k = u_k (\Gamma_i - \Psi) \quad (7)$$

Com k variando de 1 até M . Constrói-se, então, um vetor de pesos (Ω) segundo a equação 8:

$$\Omega^T = [\omega_1, \omega_2, \dots, \omega_M] \quad (8)$$

Esses pesos vão descrever a contribuição de cada "autoface" na representação de cada imagem de entrada de face. Feito isso, trata-se as "autofaces" geradas como um conjunto base para as imagens de face.

O número de pessoas contidas na fase de treinamento determina o número de classes definidas pelo sistema. Para cada pessoa, identificada como pessoa conhecida, vai ser calculado o vetor classe k através da média de "autofaces" das imagens originais dessa pessoa conhecida.

Nesse momento, determina-se a que classe a nova imagem de face vai pertencer, para isso deve-se encontrar a classe k da face que minimiza a distância Euclidiana, segundo a equação 9:

$$\epsilon_k^2 = \|\Omega - \Omega_k\|^2 \quad (9)$$

A partir do resultado desse cálculo uma imagem de face é classificada como pertencente a uma classe k quando o

mínimo ϵ_k está abaixo de um valor limite $\theta\epsilon$. Caso esse valor mínimo esteja acima do valor limite $\theta\epsilon$, a face é classificada como pessoa desconhecida.

C. Codificação do Sistema

A codificação focou no desenvolvimento de dois módulos principais de processamento: o módulo de fase de treinamento e o módulo de reconhecimento, desenvolvidos em Matlab 7.0.1 [29]. Para aumentar a usabilidade da interface, foi desenvolvida uma pequena interface em linguagem C, com o propósito apenas de ter comunicação com os módulos principais.

<pre>load variables autoface =0; %thre=1000000; %57471 omega=0; omega2=0; somaomega=0; %cam; for i=1:12 for k=1:quant imagem=imread(strcat('foto(',int2str(k),'.').jpg')); dif=imagem-media; autoface=autoface+(v(i,k)*dif); end imagem=imread (strcat('teste.jpg')); imagem=rgb2gray(imagem); dif=imagem-media; omega=times(autoface',dif);</pre>	<pre>for b=1:256 for c=1:256 omega2 (i,c_256*(b-1))=omega(b,c); end end autoface=0; end</pre>
--	---

Figura 2- Parte do código em MatLab 7.0.1 do módulo de fase de treinamento.

Na Figura 2 é apresentada parte do código relativo ao módulo de fase de treinamento, escrito para Matlab 7.0.1. Esse módulo trata as fotos tiradas via um webcam, armazenadas em um diretório, que são selecionadas e pré-classificadas através da interface com o usuário. O usuário escolhe as fotos por aluno e aciona o sistema de treinamento para criar as “autofaces” e a médias de todas as faces, que irão preencher as tabelas da matriz $M \times N$. Essas tabelas são armazenadas em formato padrão MDB, que permitem acesso via MS Access. O limiar (do inglês, *threshold*) também é fornecido pelo usuário.

IV. APLICAÇÃO DO SISTEMA E SEUS RESULTADOS

A Parâmetros para aplicação de teste do Sistema

Para testar a aplicabilidade do Sistema, utilizou-se fotos de seis alunos de uma turma de ensino médio de uma escola pública composta de dez alunos.

A aplicação teve o propósito de confirmar a precisão e a capacidade de identificação do sistema, a partir de um banco de imagens. O banco de imagens, utilizado para o treinamento, foi composto, de forma inicial, por 30 fotos, no qual, para cada um dos seis alunos, foram obtidas cinco fotos diferentes, com poses e expressões faciais diversas. Em testes anteriores [27], verificou-se que uma maior quantidade de fotos por alunos, aumenta a precisão do sistema, mas essa precisão se estabiliza após uma certa quantidade. No estudo visto em [27], observou-se que essa estabilização se fixa no momento que se utiliza entre cinco e sete fotos por aluno, sendo que a precisão fixada para essa situação (em que usa entre cinco e sete fotos por alunos) fica entre 90% e 95%. As 30 fotos de teste desse trabalho são as que estão vistas na Figura 3.

Para a fase de treinamento, as fotos tiradas foram convertidas dentro de matrizes no sistema RGB (vermelho, verde, azul em inglês), em seguida, transformou-se em uma nova foto representativa em tons de cinza. De todas essas novas fotos em tons de cinza, obteve-se uma média geral das 30 novas fotos em escala de cinza.

A partir disso, calculou-se a diferença entre essa média geral e cada nova foto em tons de cinza. Essa diferença entre as médias das fotos e cada foto em tons de cinza foi transformada de matriz para um vetor, que se tornaram duas novas matrizes: a matriz A e sua transposta A^T .

Para aumentar a precisão no módulo de reconhecimento foram inseridas 18 novas fotos dos mesmos alunos da turma e duas outras fotos extras. As duas fotos extras foram uma foto extra de uma imagem de paisagem e uma foto de um aluno que não fazia parte do grupo dos seis alunos da turma investigados nesse trabalho. Cada uma dessas novas fotos também passou pelo processo de conversão para gerar uma nova foto cinza e serem igualmente comparadas com a base de treinamento.

Uma foto das 18 extras, associadas aos alunos do teste, passou por modificações feitas por um aplicativo de desenho, simulando diferença de iluminação e eliminação de características de rosto. Isso para verificar se esse tipo de alteração causaria um efeito negativo na parte de identificação.

Para cálculo de comparação, estabeleceu-se o limiar θ_e como sendo de 100.000, sendo esse estabelecido como valor empírico, utilizando-se dos diversos valores obtidos entre as imagens durante a aplicação do protótipo.

B. Aplicação do módulo de fase de treinamento

A Figura 3, como já explicado, representa as 30 fotos que perfizeram os espaços para a montagem do módulo de treinamento do Sistema (cinco fotos para cada um dos seis alunos). Cada conjunto de fotos, por aluno, gerou uma classe específica denominada *student*, com suas instâncias sendo *student 1*, *student 2* e assim por diante. Cada uma distinta para cada aluno do grupo.

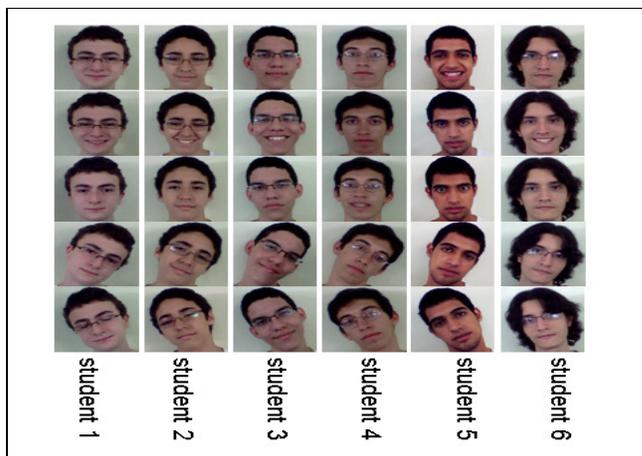


Figura 3 – Fotos dos seis alunos (classe *Student*), em cinco poses distintas para cada um deles.

Com base nesse conjunto total de fotos foi possível obter, aplicando-se as equações indicadas na seção 3. Foi computada a média das imagens, gerando uma nova imagem de acordo com apresentado na Figura 4.



Figura 4 - Média das imagens obtidas

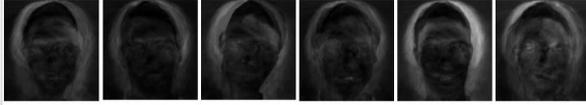


Figura 5 – Seis “autofaces” geradas para cada grupo de fotos por aluno.

Em conjunto a essa operação, para cada arranjo de fotos por aluno, construíram-se as classes k de “autofaces” para serem usadas no reconhecimento, com o objetivo de classificar uma nova face como conhecida, desconhecida ou fora do escopo. A Figura 5 apresenta seis dessas “autofaces”, utilizadas no reconhecimento, associadas a cada aluno da Figura 3.

C. Aplicação do módulo de reconhecimento

Para o módulo de reconhecimento foram inseridas de forma aleatória novas fotos associadas aos alunos, de acordo com o apresentado na Figura 6, sendo que a organização vista na Figura 6 serve apenas para facilitar a identificação das mesmas nesse trabalho, mas a ordem de entrada no Sistema foi, como dito, aleatória.

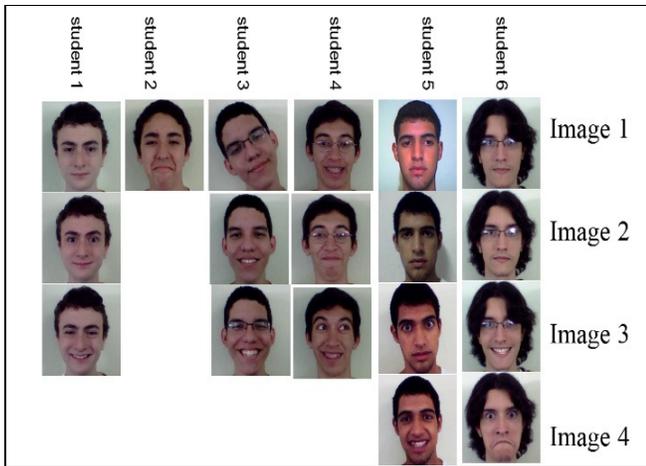


Figura 6 – Novas fotos inseridas, em uma organização apenas visual, na qual o eixo horizontal identifica os alunos e o eixo vertical quais as novas imagens inseridas.

Cada grupo de novas fotos por aluno foi submetido ao Sistema, via módulo de reconhecimento, com vistas a verificar se a foto era conhecida ou desconhecida, e, caso fosse conhecida, a qual classe *student* pertenceria. Foi seguido o procedimento:

- Cada foto nova foi inserida direta no módulo de reconhecimento (ou seja, não foi submetida ao treinamento) e tratada para poder ser reconhecida, ou não, dentro da base de imagens criada na fase de treinamento. Por exemplo, com a *image 2* do *student 5* da Figura 6 e, aplicando-se a Equação 7, obteve-se uma nova projeção no espaço de “autofaces”, conforme visto na Figura 7.
- Construiu-se o vetor de pesos Ω^T conforme visto na Figura 8.
- Cada aluno, com suas fotos anteriores, foi inserido na base de imagens segundo sua classificação, *student 1*, *student 2* e assim por diante até o *student 6*, segundo os vetores Ω_k que servem para agrupar.
- Com o novo vetor de “autoface” da nova foto, calculou-se a distância, segundo a equação Euclidiana do item III. A distância abaixo do limite θ_c permitiu identificar a *image 2* do *student 5* da Figura 6 como uma mesma imagem associada à classe *student 5*. Isso pode ser visto na Figura 9.

Em outros exemplos, visto nas Figuras 10 e 11, as novas imagens (*image 1*, *image 2* e *image 3*) do *student 1* da Figura 6 foram submetidas ao Sistema, que as identificou e confirmou como sendo da classe *student 1*; e as imagens *image 1*, *image 2* e *image 3* do *student 4* também confirmaram ser da classe *student 3*.



Figura 7 - *Image 2* da classe *student 5* como uma projeção para “autofaces”.

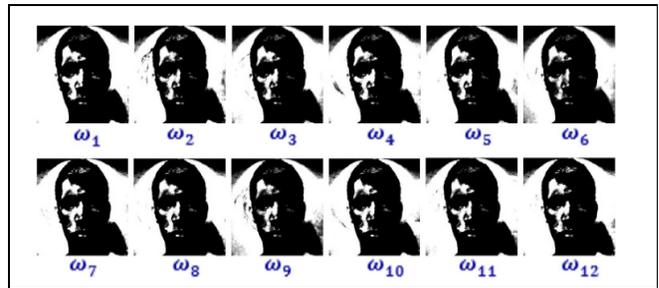


Figura 8 – Vetor Ω^T , considerando 12 imagens.

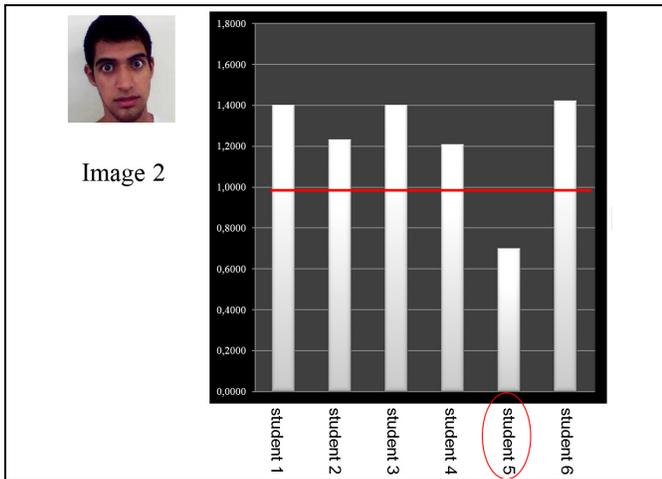


Figura 9 – Resultado após cálculo da distância, onde se percebe que a *image 2* está com o menor limiar no espaço associado à classe *student 5*.

Na Figura 12 são observadas as duas outras imagens (*Image* e *Paisagem*), que também foram submetidas a verificação pelo Sistema. A primeira imagem (*Image*) é de um aluno fora da listagem da figura 3. Esse exemplo foi utilizado para averiguar se o sistema alertaria para uma foto normal que não estivesse dentro do espaço de “autofaces”. A outra é uma imagem de uma paisagem, que foi inserida no teste de modo a confirmar que o sistema identificaria uma foto irregular fora do contexto e alertaria o fato dela também não pertencer ao conjunto de fotos de faces.

Ao serem submetidas ao módulo de reconhecimento, ambas aparecem com a distância acima do limiar, indicando que não pertenciam ao espaço de “autofaces”, e, por isso, não puderam ser atribuídas a nenhuma das classes *student* já existentes nesse espaço. Mesmo a imagem do aluno sendo uma face, ela não foi reconhecida dentro do espaço de “autofaces” do sistema treinado.

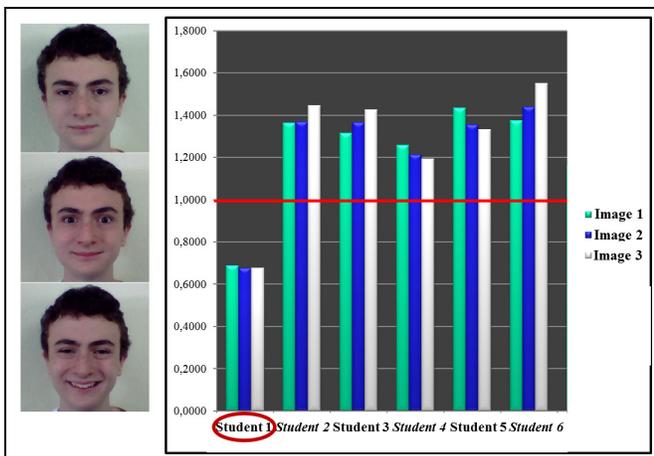


Figura 10 – Análise das novas imagens obtidas, associadas e classificadas na classe *student 1* de forma correta.

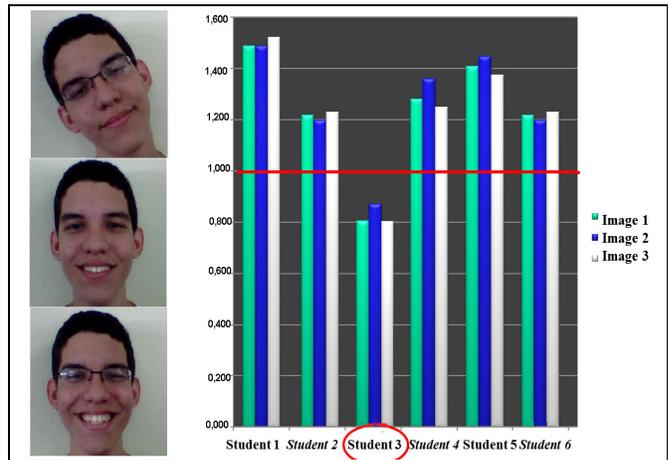


Figura 11 – Análise das novas imagens obtidas, que foram associadas e classificadas na classe *student 3* de forma correta.

Na figura 13, é visto a *image X* associada à classe *student 5* (figura 3), mas com a diferença de que essa foto, em relação a outras da classe *student 5* da figura 3, foi submetida a um tratamento para dar efeito de iluminação e retirada de pequenas características do rosto.

Esse tratamento de iluminação foi o fator de contribuição para aumentar a distância de reconhecimento, pois esse tratamento de iluminação modificou a escala de cinza, fazendo a matriz de autovalores ficar fora do espaço da base de imagens treinada. O Sistema apresentou essa sensibilidade a fatores de iluminação, o que identificou os 5% de falha na precisão relatados anteriormente.

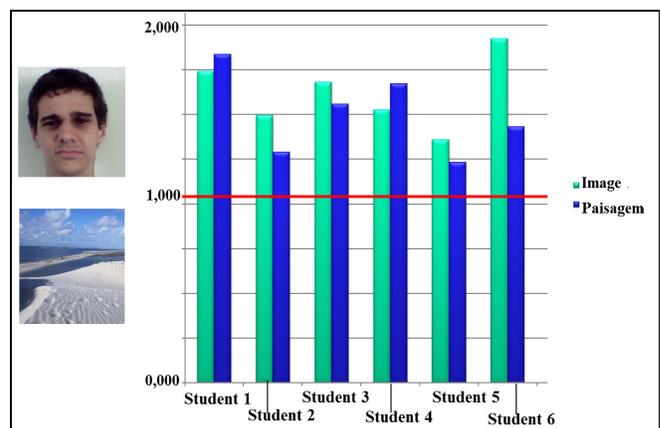


Figura 12 – Imagens não reconhecidas no espaço de “autofaces” e por isso classificadas como desconhecidas.

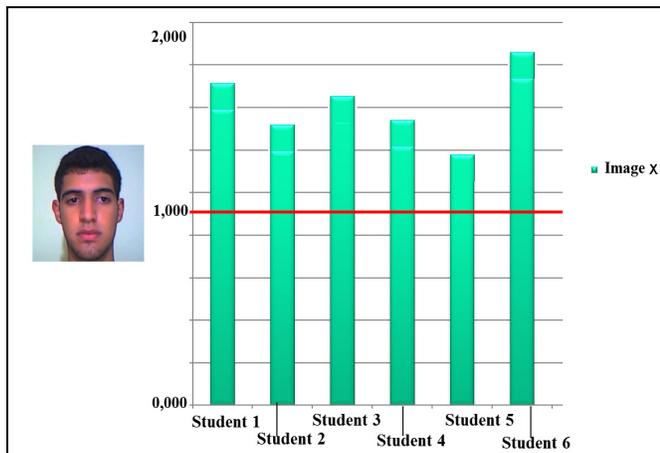


Figura 13 – *Image X*, que passou por processo de alteração para parecer mais iluminada, também classificada como desconhecida.

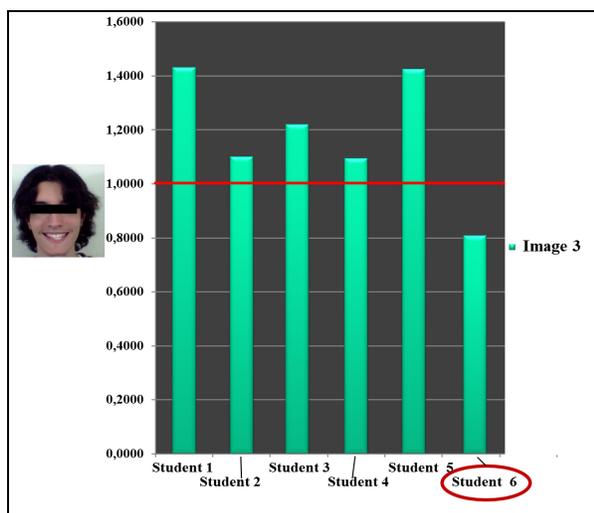


Figura 14 - Imagem que foi alterada, com uma tarja sobre os olhos, mas que foi reconhecida como face e dentro da base de imagens, classificada, dentro do esperado, como da classe *student 6*.

Contudo, a *image X* da Figura 13 poderia ser realocado na fase de treinamento para que o Sistema pudesse reajustar as escalas de iluminação e, por fim, a reconhecesse como uma face válida.

Já nas Figuras 14 e 15, novas fotos, no caso a *image 3* do *student 6* e *image 3* do *student 3*, ambos da Figura 6, foram cobertas com uma faixa em preto (sobre os olhos no caso do *student 6* e sobre a boca no caso do *student 3*), gerando o que seria novas foto. Ambas também foram submetidas ao Sistema. Assim mesmo, foram identificadas como uma foto dentro do espaço de “autofaces” da base de imagens, associada à classe *student 6* e a classe *student 3*.

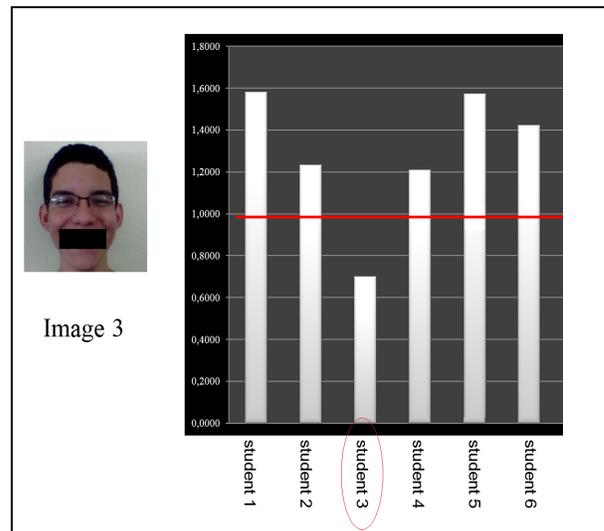


Figura 15 - Imagem que foi alterada, com uma tarja preta sobre a boca, mas que foi reconhecida como face e dentro da base de imagens, classificada, dentro do esperado, como da classe *student 3*.

O problema de identificação na foto da Figura 12, ocorreu por ter havido alteração manipulada na sua escala de cinza, pois a mesma foi manipulada para ser vista como mais iluminada. O Sistema também pode identificar fotos que não pertenciam ao conjunto de faces do banco de imagens fortalecendo sua característica como instrumento de segurança.

Também foi possível verificar que o Sistema conseguiu identificar fotos fora do contexto (como a paisagem da Figura 11), impedindo tentativas de burlar os critérios de segurança.

Mesmo com fotos alteradas, como visto na Figura 13, mas que não tivessem problemas de alteração na escala de cinza, foi possível ao Sistema prover a correta identificação dentro do espaço de “autofaces”.

V. CONCLUSÕES

O Sistema demonstrou ser capaz de auxiliar no controle da presença dos alunos, de forma automatizada, com robustez e precisão tanto para anotar a presença dos alunos em sala de aula, quanto para informar situações de desconhecimento sobre pessoas na sala, seja por foto inadequada, foto de aluno não pertencente a turma ou foto fora do contexto.

Percebeu-se que o fator iluminação influencia no reconhecimento da imagem, pois o mesmo modifica a escala de cinza da imagem fazendo que a matriz de autovalores fique fora do espaço das imagens de treinamento do sistema.

Desse modo, a utilização desse sistema como instrumento de controle de presença e segurança mostrou-se viável e adequado a essas funções de modo satisfatório. A quantidade de fotos que fizeram o banco de imagens e que foi de cinco fotos por aluno, foi suficiente para garantir um grau de precisão robusto.

É possível a substituição de mecanismo de verificação de presença manuais, como listas, ou mesmo sistema biométricos simples, por esse tipo de sistema, sem perder a capacidade de

garantir um controle de presença e segurança, dentro de um grau de precisão aceitável.

Devido ao seu grau de precisão, estuda-se que um novo módulo a ser incorporada é a de identificação geral de faces. Esse acrescentaria ao Sistema a operação na qual a partir de uma foto com a imagem de toda a turma, identificar-se-ia todos os rostos na foto e em seguida utilizar-se-ia dos módulos já programados para tratar do reconhecimento e identificação de cada aluno na sala de aula.

Há também uma nova linha de desenvolvimento desse Sistema, com uso de robôs de captação de imagens, associados a clusters, para operação sobre essas imagens e, também, a utilização de versões desse Sistema para trabalho com veículos aéreos não tripulados, com vistas a auxiliar na identificação de intrusos em instalações públicas.

AGRADECIMENTOS

Agradecemos ao CEFET/RJ, ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Fundação de Apoio à Pesquisa do Estado do Rio de Janeiro (FAPERJ) pelos fomentos e aos alunos do sexto período de Informática, que participaram voluntariamente do teste.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] Kpalma K. & Ronsin, J. An Overview of Advances of Pattern Recognition Systems in Computer Vision in: Vision Systems: Segmentation and Pattern Recognition, Edited by: Goro Obinata and Ashish Dutta, 170-197, Vienna: Austria, doi: 10.5772/4960, 2008.
- [2] Rosa, R.P.; Porto, M. A. & Kozakevicius, A. "Classificador de Imagens de Pulmão Utilizando Wavelets de Haar e Distância de Malhalanobis" Revista de Informática Teórica e Aplicada, UFRG, Brasil, V22, N1, 2015.
- [3] Bishop, C. M. Neural Networks for Pattern Recognition. Clarendon Press. Oxford:UK, 1995.
- [4] Zhao, W & Chellappa, R. Face Processing: Advanced Modeling and Methods. Academic Press Inc. Orlando: USA, 2010.
- [5] DINIZ, F. A. et al. RedFace: um sistema de reconhecimento facial baseado em técnicas de análise de componentes principais e autofaces: comparação com diferentes classificadores. Revista Brasileira de Computação Aplicada, Passo Fundo, v. 5, n. 1, p. 42-54, 2013.
- [6] Jagadiswary, D & Saraswady, D. Biometrics authentication using fused multimodal biometrics, Procedia Computer Science, V85, P 109-116 2016.
- [7] Kitani, E.C.; Hernandez, E.M.; Giraldo, G. A. & Thomaz., C.E Exploring and understanding the high dimensional and sparse image face space: a self-organized manifold mapping. In: Peter. Corcoran, Ed. (Org.). New Approaches to Characterization and Recognition of Faces. Rijeka: InTech, 225-238, 2011.
- [8] Lipschutz, S Álgebra Linear: Coleção Schaum. Ed Bookman. São Paulo: Brasil, 2015.
- [9] Conci, A. et all Computação Gráfica: Teoria e Prática. Ed Elsevier. V2, Rio de Janeiro: Brasil 2012.
- [10] Solomon, C. Fundamentos de Processamento Digital de Imagens, Ed LTC, Brasil, 2013.
- [11] Gonzalez, R. & Woods, R. Processamento de Imagens Digitais. Ed Edgard Blücher. São Paulo:Brasil, 2015.
- [12] Augusto, F. R Localização e Reconhecimento de Placas de Sinalização Utilizando um Mecanismo de Atenção Visual e Redes Neurais Artificiais. Tese (mestrado) Universidade Federal de Campina Grande (UFCG), Brasil, 2002.
- [13] Viola P. & Jones, M.J. Robust real-time face detection. International Journal of Computer Vision, 57(2), 137-154, 2004.
- [14] Silva, A. L. & Cintra, M. E Reconhecimento de padrões faciais: Um estudo. In: Encontro Nacional de Inteligência Artificial e Computacional, 2015, Proceedings ENIAC, 224-231, 2015.
- [15] Sun, L. J. & Wang, S. Pattern Recognition: An overview. International Journal of Computer Science and Network Security (IJCSNS), 6(6), 2006.
- [16] Castejon, E. F.; Fonseca, L. M. & Arcanjo, J.S. Melhoria da geometria e posicionamento de imagens orbitais de média resolução Um experimento com dados CBERS-CCD. Anais XVI Simpósio Brasileiro de Sensoriamento Remoto – SBSR, Brasil, 2013.
- [17] Vapnik, V N An overview of statistical learning theory. IEEE Transactions on Neural Networks 10(5), 988-999, 1999.
- [18] D. Chen, X. Cao, L. Wang, F. Wen, and J. Sun. Bayesian face revisited: A joint formulation. In Proc. ECCV, pages 566-579, 2012.
- [19] Pal, S.K. & Pal, A. Pattern recognition: from classical to modern approaches, ISBN No. 981-02-4684-6, Singapore, 2002.
- [20] Munich, M. E.; Pirjanian, P.; Di Bernardo, E.; Goncalves, L.; Karlsson, N. & Lowe, D. Application of Visual Pattern Recognition to Robotics and Automation, IEEE Robotics & Automation Magazine, 72-77, 2006.
- [21] López, M; Montes, A.J.H.; Ramirez, R.V.; Hernández, G.A.; Cabada, Z. & Estrada, M.L.B. EmoRemSys: Sistema de recomendación de recursos educativos basado en detección de emociones, RISTI- Revista Ibérica de Sistemas y Tecnologías de Información, 17(3), 2016.
- [22] Turk, M & Pentland, A. Eigenfaces for Recognition, Journal of Cognitive Neuroscience, 3(1), 71-86, 1991.
- [23] Filho, C. F. F., Falcão, T, A & Costa, M. C. F. Proposing the novelty classifier for face recognition. Revista Brasileira de Engenharia. Biomédica., 30(4), 2014.
- [24] EBRAHIMPOUR, R. et al. Low resolution face recognition using mixture of experts with different representations. In: IEEE. Soft Computing and Pattern Recognition (SoCPaR), 2011 International Conference of. [S.l.], p. 475-480, 2011.
- [25] C. Lu and X. Tang. Surpassing human-level face verification performance on lfw with gaussianface. AAAI, 2015.
- [26] Le, T. H & Bui L. Face recognition based on SVM and 2DPCA. International Journal of Signal Processing, Image Processing and Pattern Recognition. 4(3), pp 85-94, 2011.
- [27] Quadros, J. R. T.; Gonçalves, L. B & Pachao Junior, F. Sistema de reconhecimento facial para controle automático de presença em sala de aula. Iberian Conference on Information System and Technologies, Lisbon:Portugal, 2017.
- [28] Cha, S.H. Comprehensive Survey on Distance/Similarity Measures between Probability Density Functions. International Journal of Mathematical Models and Methods in Applied Sciences. 1(4), 300-307, 2007.
- [29] Chapman, S. T Programação em MatLab para Engenheiros, Ed Thomson, Brasil, 2012.